



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE INFORMÁTICA

RODRIGO MESEL LOBO OLIVEIRA

**FOUNDATION MODELS NO MERCADO FINANCEIRO:
uma comparação entre modelos de base e random forest**

Recife
2025

RODRIGO MESEL LOBO OLIVEIRA

**FOUNDATION MODELS NO MERCADO FINANCEIRO:
uma comparação entre modelos de base e random forest**

Trabalho de Conclusão de Curso
apresentado ao Curso de Ciência da
Computação da Universidade Federal de
Pernambuco, como requisito parcial para
obtenção do título de Bacharel em Ciência
da Computação

Orientador: Adriano Lorena Inácio de Oliveira

Recife
2025

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Oliveira, Rodrigo Mesel Lobo.

Foundation models no mercado financeiro: uma comparação entre modelos de base e random forest / Rodrigo Mesel Lobo Oliveira. - Recife, 2025.

57 p. : il., tab.

Orientador(a): Adriano Lorena Inacio de Oliveira

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de Pernambuco, Centro de Informática, Ciências da Computação - Bacharelado, 2025.

Inclui referências, apêndices.

1. Aprendizagem de máquina. 2. Aprendizagem profunda. 3. Chronos. 4. TimeFM. 5. Day Trade. 6. Mercado financeiro. I. Oliveira, Adriano Lorena Inacio de. (Orientação). II. Título.

000 CDD (22.ed.)

RODRIGO MESEL LOBO OLIVEIRA

**FOUNDATION MODELS NO MERCADO FINANCEIRO:
uma comparação entre modelos de base e random forest**

Trabalho de Conclusão de Curso
apresentado ao Curso de Ciência da
Computação da Universidade Federal de
Pernambuco, como requisito parcial para
obtenção do título de Bacharel em Ciência
da Computação

Aprovado em: 28/07/2025

BANCA EXAMINADORA

Prof. Adriano Lorena Inácio de Oliveira (Orientador)
Universidade Federal de Pernambuco

Prof. Cleber Zanchettin (Examinador Interno)
Universidade Federal de Pernambuco

AGRADECIMENTOS

Agradeço, em primeiro lugar, aos meus pais, pelo apoio incondicional em todos os momentos da minha vida. Sou imensamente grato por todo o incentivo, amor e pelas inúmeras oportunidades que me proporcionaram ao longo da minha jornada. Sem o suporte deles, nenhuma das minhas conquistas teria sido possível.

Quero agradecer também aos meus professores de graduação, que desempenharam um papel fundamental na minha formação acadêmica e pessoal. O corpo docente do Centro de Informática é, sem dúvida, responsável por fazer desta instituição um centro de excelência reconhecido nacional e internacionalmente.

Agradeço à minha namorada, Marina, por caminhar ao meu lado durante toda essa jornada. Seu amor, paciência, companheirismo e incentivo constante foram essenciais nos momentos de maior desafio, e seu apoio foi um verdadeiro combustível que me impulsionou durante a graduação.

Aos meus amigos, em especial Artur, Bruna, Gustavo, José Lucas, Lucas, Matheus e Raíssa, deixo meu sincero agradecimento por tornarem a vivência no Centro de Informática mais leve, divertida e significativa. Compartilhar essa trajetória com pessoas tão especiais fez toda a diferença.

A todos que, direta ou indiretamente, contribuíram para que este trabalho fosse realizado, o meu mais profundo agradecimento.

RESUMO

Este trabalho investiga a aplicabilidade de *foundation models* no mercado financeiro brasileiro, com foco na previsão de preços de ações. O objetivo é verificar se esses modelos, mesmo sem ajustes específicos (*zero-shot*), podem alcançar desempenho competitivo. Foram utilizados dois modelos: *TimesFM* e *Chronos*, sendo este último também avaliado com *fine-tuning*.

Os resultados foram comparados com os de um modelo *Random Forest* treinado diretamente sobre os dados financeiros. Embora os *foundation models* tenham demonstrado potencial, especialmente quando submetidos a *fine-tuning* com o uso de covariáveis, o *Random Forest* apresentou desempenho mais consistente nas ações analisadas. Esses resultados reforçam a eficácia de modelos tradicionais bem ajustados no contexto da B3, mas também apontam que modelos de base, quando devidamente adaptados, podem se tornar alternativas viáveis e promissoras para aplicações futuras no mercado financeiro.

Palavras-chave: Aprendizagem de máquina; Aprendizagem profunda; *Chronos*; *TimeFM*; *Day Trade*; Mercado financeiro.

ABSTRACT

This study investigates the applicability of *foundation models* in the Brazilian financial market, focusing on stock price forecasting. The goal is to assess whether these models, even without specific adjustments (*zero-shot*), can achieve competitive performance. Two models were used: *TimesFM* and *Chronos*, the latter also being evaluated with *fine-tuning*.

The results were compared with those of a *Random Forest* model trained directly on financial data. Although the *foundation models* showed potential, especially when fine-tuned with the use of covariates, the *Random Forest* delivered more consistent performance across the analyzed stocks. These findings reinforce the effectiveness of well-tuned traditional models in the context of the B3, while also suggesting that *foundation models*, when properly adapted, may become viable and promising alternatives for future applications in the financial market.

Keywords: *Machine Learning; Deep Learning; Chronos; TimeFM; Day Trade; Financial Market.*

LISTA DE ILUSTRAÇÕES

Figura 1 –	Representação dos períodos utilizados para treinamento, validação e teste, com suas respectivas durações em dias.	19
Figura 2 –	Visão geral do <i>Chronos</i>	22
Figura 3 –	Visão geral do sistema	23
Figura 4 –	Regras de negociações	27
Figura 5 –	Exemplos de <i>Drawdowns</i>	28
Figura 6 –	Previsão do valor máximo diário da ação ABEV3 utilizando o modelo <i>Random Forest</i>	31
Figura 7 –	Previsão do valor mínimo diário da ação EGIE3 utilizando modelo <i>Random Forest</i>	31
Figura 8 –	Previsão do valor máximo diário da ação JBSS3 utilizando o modelo <i>Random Forest</i>	32
Figura 9 –	Previsão do valor máximo diário da ação ABEV3 utilizando o modelo <i>TimesFM</i>	33
Figura 10 –	Previsão do valor mínimo diário da ação EGIE3 utilizando o modelo <i>TimesFM</i>	33
Figura 11 –	Previsão do valor máximo diário da ação JBSS3 utilizando o modelo <i>TimesFM</i>	34
Figura 12 –	Previsão do valor máximo diário da ação ABEV3 utilizando o modelo <i>Chronos (zero-shot)</i>	35
Figura 13 –	Previsão do valor mínimo diário da ação EGIE3 utilizando o modelo <i>Chronos (zero-shot)</i>	35
Figura 14 –	Previsão do valor máximo diário da ação JBSS3 utilizando o modelo <i>Chronos (zero-shot)</i>	36
Figura 15 –	Previsão do valor máximo diário da ação ABEV3 utilizando o modelo <i>Chronos</i>	37
Figura 16 –	Previsão do valor mínimo diário da ação EGIE3 utilizando o modelo <i>Chronos</i>	37
Figura 17 –	Previsão do valor máximo diário da ação JBSS3 utilizando o modelo <i>Chronos</i>	38
Figura 18 –	Resultados simulação <i>day trading Chronos (Fine tuned) x Random Forest (30%) - ABEV3</i>	46

Figura 19 –	Resultados simulação <i>day trading Chronos (Fine tuned)</i> x <i>Random Forest (25%)</i> - BBDC4	47
Figura 20 –	Resultados simulação <i>day trading Chronos (Fine tuned)</i> x <i>Random Forest (Sem incerteza)</i> - EGIE3	48
Figura 21 –	Resultados simulação <i>day trading TimesFM</i> x <i>Random Forest (10%)</i> - ITUB4	49
Figura 22 –	Resultados simulação <i>day trading Chronos (Zero Shot)</i> x <i>Random Forest (45%)</i> - JBSS3	50
Figura 23 –	Resultados simulação <i>day trading Chronos (Zero Shot)</i> x <i>Random Forest (5%)</i> - PETR4	51

LISTA DE TABELAS

Tabela 1 –	Variáveis originais do primeiro <i>dataset</i>	19
Tabela 2 –	Variáveis originais do segundo <i>dataset</i>	20
Tabela 3 –	Análise da incerteza ABEV3 (<i>CHRONOS</i>)	39
Tabela 4 –	Análise da incerteza ABEV3 (<i>RANDOM FOREST</i>)	39
Tabela 5 –	Análise da incerteza BBDC4 (<i>CHRONOS</i>)	40
Tabela 6 –	Análise da incerteza BBDC4 (<i>RANDOM FOREST</i>)	40
Tabela 7 –	Análise da incerteza EGIE3 (<i>CHRONOS</i>)	41
Tabela 8 –	Análise da incerteza EGIE3 (<i>RANDOM FOREST</i>)	41
Tabela 9 –	Análise da incerteza ITUB4 (<i>CHRONOS</i>)	42
Tabela 10 –	Análise da incerteza ITUB4 (<i>RANDOM FOREST</i>)	42
Tabela 11 –	Análise da incerteza JBSS3 (<i>CHRONOS</i>)	43
Tabela 12 –	Análise da incerteza JBSS3 (<i>RANDOM FOREST</i>)	43
Tabela 13 –	Análise da incerteza PETR4 (<i>CHRONOS</i>)	44
Tabela 14 –	Análise da incerteza PETR4 (<i>RANDOM FOREST</i>)	44
Tabela 15 –	Comparação resultados da simulação de <i>day trading</i> - ABEV3	46
Tabela 16 –	Comparação resultados da simulação de <i>day trading</i> - BBDC4	47
Tabela 17 –	Comparação resultados da simulação de <i>day trading</i> - EGIE3	48
Tabela 18 –	Comparação resultados da simulação de <i>day trading</i> - ITUB4	49
Tabela 19 –	Comparação resultados da simulação de <i>day trading</i> - JBSS3	50
Tabela 20 –	Comparação resultados da simulação de <i>day trading</i> - PETR4	51

LISTA DE ABREVIATURAS E SIGLAS

ANN	Redes Neurais Artificiais
MDD	Máximo <i>Drawdown</i>
RF	<i>Random Forest</i>

SUMÁRIO

1	INTRODUÇÃO	14
2	TRABALHOS RELACIONADOS	16
3	METODOLOGIA	18
3.1	DADOS	18
3.1.1	<i>Datasets</i>	18
3.1.2	Tratamento dos dados	20
3.2	MODELOS	21
3.2.1	<i>Foundation models</i>	21
3.2.2	<i>Chronos</i>	21
3.2.3	<i>TimesFM</i>	22
3.3	SISTEMA	22
3.4	<i>FINE TUNING NO CHRONOS</i>	23
3.5	INCERTEZA	24
3.5.1	Cálculo da incerteza	24
3.5.2	Uso da incerteza	25
3.6	<i>DAY TRADING</i>	26
3.6.1	Regras para compra e venda dos ativos	26
3.6.2	Controle de riscos	27
3.6.3	<i>Drawdown</i>	28
3.7	COMPARAÇÃO COM O <i>RANDOM FOREST</i>	29
4	RESULTADOS	30
4.1	PREVISÕES DE MÁXIMA E MÍNIMA	30
4.1.1	Predições com <i>Random Forest</i>	30
4.1.2	Predições com <i>TimesFM</i>	33
4.1.3	Predições com <i>Chronos zero-shot</i>	34
4.1.4	Predições com <i>Chronos pós Fine Tuning</i>	36
4.2	SISTEMA DE <i>DAY TRADING</i>	38

4.2.1	Análise da incerteza	38
4.2.2	Operações de <i>day trading</i>	45
4.2.2.1	Abev3	46
4.2.2.2	Bbdc4	47
4.2.2.3	Egie3	48
4.2.2.4	Itub4	49
4.2.2.5	Jbss3	50
4.2.2.6	Petr4	51
5	CONCLUSÃO	53
6	LIMITAÇÕES E TRABALHOS FUTUROS	54
	REFERÊNCIAS	55
	APÊNDICE A - LINKS PARA COMPLEMENTOS DIGITAIS	57

1 INTRODUÇÃO

O mercado financeiro é um dos ambientes mais complexos e voláteis da economia, caracterizado por uma grande quantidade de variáveis interdependentes e eventos imprevisíveis que afetam diretamente os preços dos ativos. Entre as diversas estratégias de operação existentes, o *day trading* tem ganhado destaque, sendo definido como a prática de comprar e vender ativos no mesmo dia com o objetivo de lucrar com pequenas oscilações de preço. Essa estratégia exige decisões rápidas, alto nível de precisão e o uso de ferramentas computacionais para análise e previsão de tendências [13].

Com o avanço das técnicas de inteligência artificial nos últimos anos, modelos de aprendizado de máquina têm sido amplamente utilizados para resolver problemas complexos em diversas áreas, incluindo saúde, linguagem natural, logística e finanças [5]. No contexto do mercado financeiro, a previsão de preços de ativos é uma das aplicações mais desafiadoras, devido à sua natureza volátil, não linear e fortemente influenciada por fatores externos e aleatórios [4].

Tradicionalmente, métodos estatísticos e modelos supervisionados como regressão linear, ARIMA e *Random Forest* têm sido utilizados como tentativas para realizar a predição de tendências de mercado e auxiliar na tomada de decisões de compra e venda de ações [7]. No entanto, com o surgimento de modelos de base, ou seja, algoritmos de aprendizado profundo pré-treinados em grandes volumes de dados [8], surge a possibilidade de aplicar esses modelos a novas tarefas com pouca ou nenhuma adaptação por meio de técnicas como o *zero-shot learning* ou o *fine-tuning* [2].

Modelos como o *TimesFM* [6] e o *Chronos* [1] foram criados com a ideia de serem mais versáteis em tarefas envolvendo séries temporais. Eles prometem mais flexibilidade e melhor desempenho em diferentes áreas, incluindo o mercado financeiro. No entanto, ainda são poucos os estudos que analisam com mais profundidade como esses modelos se saem especificamente no contexto do mercado financeiro brasileiro.

Diante desse cenário, este trabalho propõe a aplicação dos modelos *TimesFM* e *Chronos* na tarefa de previsão de preços de ações da B3, avaliando seu desempenho tanto em modo *zero-shot* quanto com *fine-tuning* (aplicado apenas ao *Chronos*). Os resultados obtidos serão comparados com os de um modelo *Random*

Forest treinado no mesmo contexto [11], com o intuito de verificar se os *foundation models* podem, de fato, superar abordagens tradicionais nesse domínio específico.

Também será avaliado se a utilização da incerteza como critério para a realização de compras e vendas, permitindo que essas operações ocorram apenas em dias com baixa incerteza nas previsões, contribui para um desempenho superior ao final do período analisado. Essa estratégia também foi adotada no modelo *Random Forest* [9].

Com essa análise, busca-se contribuir para o entendimento sobre o potencial e as limitações dos *foundation models* em aplicações financeiras, bem como fornecer subsídios para futuras pesquisas que desejem explorar esses modelos em contextos semelhantes.

2 TRABALHOS RELACIONADOS

A estimativa de preços de ações é um tópico amplamente explorado na pesquisa científica, abrangendo desde modelos estatísticos clássicos até métodos modernos de inteligência artificial. Este estudo se baseia nas contribuições de Albuquerque Filho [10], Albuquerque Junior [11], que exploraram o uso do modelo *Random Forest Regressor* para o desenvolvimento de estratégias de *Day Trade* e o de Vasconcelos Sobral [9] que analisou o impacto do uso da incerteza no modelo anterior.

Em 2009, Martinez [12] desenvolveu um modelo utilizando Redes Neurais Artificiais (*ANN*) para realizar a previsão dos valores máximos e mínimos diários de ações, utilizando como base indicadores técnicos e o preço de abertura do mercado. As estimativas geradas pelo modelo foram utilizadas em um sistema automatizado de negociações com operações a cada 15 minutos, sendo avaliadas por métricas como rentabilidade e *drawdown*, aplicadas a ativos como PETR4 e VALE4.

A partir desse trabalho clássico de Martinez, Albuquerque Filho [10] utilizou o modelo *Random Forest Regressor* no mesmo contexto que Martinez fez com o *ANN*. Ele também criou um mecanismo de correção dinâmica das previsões, ajustado conforme os erros e o desvio padrão observados durante a fase de validação. Essa estratégia permitiu aumentar o montante final sem elevar o nível de *drawdown*, indicando maior eficiência no modelo proposto.

Albuquerque Junior [11] se baseou no trabalho de Albuquerque Filho [10] e desenvolveu um sistema mais avançado para operações de *day trade*. Usando também o modelo *Random Forest Regressor*, sua pesquisa analisou o efeito de diferentes combinações de indicadores técnicos na previsão de preços, além de testar variações nas regras operacionais, como critérios de compra, venda e aplicação de *stop-loss*. O desempenho do sistema foi avaliado com base em seis ações da bolsa brasileira ao longo de um período de um ano, utilizando métricas como *MAPE* (Erro Percentual Absoluto Médio), retorno anual e máximo *drawdown*.

O terceiro trabalho utilizado como base para esse projeto foi o de Vasconcelos Sobral [9], que aplicou, no mesmo contexto utilizado por Albuquerque Júnior [11], a métrica de incerteza como critério estratégico para a realização de operações intra diárias. De forma que o sistema desenvolvido por Albuquerque Júnior [11] só realizaria as operações caso a incerteza das previsões de máxima e

mínima do dia fosse baixa. Com isso, ele avaliou que essa métrica contribuiu para um aumento do montante final e para uma redução do máximo *drawdown*.

Fora do contexto do mercado financeiro, nos últimos anos, o avanço dos modelos de aprendizado profundo e, mais recentemente, dos chamados *foundation models*, abriu novas possibilidades para tarefas de previsão em diversos domínios. Bommasani et al. [2] discutem o conceito de *foundation models* como sistemas treinados em larga escala, capazes de serem adaptados para diferentes tarefas com pouca ou nenhuma personalização. Esses modelos têm sido amplamente explorados em áreas como processamento de linguagem natural e visão computacional, mas seu uso em séries temporais ainda é relativamente recente.

Esses estudos servem de base para a proposta deste trabalho, que tem como objetivo comparar os resultados obtidos pelo modelo *Random Forest Regressor* [11], em conjunto com a aplicação da métrica de incerteza [9], com os resultados provenientes da utilização de *foundation models* no mesmo contexto.

O principal diferencial deste estudo em relação aos trabalhos anteriores é a aplicação de modelos de base mais recentes, como o *TimesFM* e o *Chronos*, que dispensam treinamento prévio por já terem sido treinados em larga escala, inclusive com dados sintéticos. Nesses modelos, os dados são utilizados como contexto, ou seja, são fornecidos como entrada ao modelo para que ele possa realizar as previsões da próxima janela de tempo. O objetivo foi avaliar se esses modelos modernos, mesmo em modo *zero-shot*, já seriam capazes de competir com abordagens consolidadas no mercado financeiro.

3 METODOLOGIA

Esta seção descreve a abordagem adotada para avaliar a aplicabilidade de modelos de base na previsão de preços de ações no mercado financeiro brasileiro. O estudo foi conduzido por meio de experimentos com os modelos *TimesFM* e *Chronos*, utilizados tanto em modo *zero-shot* quanto com *fine-tuning*, e comparados ao desempenho de um modelo tradicional *Random Forest*. As etapas metodológicas envolvem a seleção e o pré-processamento dos dados, a apresentação dos modelos utilizados, a descrição geral do sistema proposto, o detalhamento do processo de *fine-tuning* aplicado ao modelo *Chronos*, a abordagem adotada para o uso da incerteza nas previsões, o funcionamento do sistema de *day trading*, e, por fim, a explicação sobre os critérios utilizados na comparação dos resultados com o modelo *Random Forest*. As subseções a seguir detalham cada uma dessas etapas.

3.1 DADOS

Esta seção explica como eram constituídos os *datasets* originais e quais tratamentos de dados foram realizados nos mesmos

3.1.1 *Datasets*

Este trabalho utilizou os mesmos conjuntos de dados empregados nos estudos de Sobral [9] e Albuquerque Filho [10]. O primeiro *dataset* é composto por informações diárias de seis ações brasileiras — ABEV3, BBDC4, EGIE3, ITUB4, JBSS3 e PETR4 — ao longo de 784 dias, abrangendo o período de 2 de abril de 2018 a 1º de junho de 2021. As variáveis disponíveis incluem: preço de abertura, preço de fechamento, máxima e mínima diária, volume de operações, volume de ações negociadas e o *spread*. No entanto, as três últimas variáveis foram descartadas nesta análise por não contribuírem significativamente para os objetivos do estudo. A tabela 1 ilustra as variáveis originais deste *dataset*.

Esse conjunto de dados foi dividido em três partes: treinamento, validação e teste. O conjunto de validação foi utilizado, principalmente, para o cálculo dos intervalos de incerteza [9], que foram posteriormente aplicados juntamente com o conjunto de testes para simular estratégias de tomada de decisão. O conjunto de treinamento foi utilizado como contexto para quando os modelos foram executados

de forma *zero-shot*, e também para realizar o *fine-tuning* do *chronos*. A figura 1 ilustra como essa divisão foi realizada.

Tabela 1 – Variáveis originais do primeiro *dataset*

Coluna	Significado
DATE	Data a que os dados se referem.
TIME	Momento que os dados foram coletados, esta coluna só está presente no dataset de operações.
OPEN	Preço de abertura da ação, corresponde à primeira operação realizada no dia, a partir das 10:00h. Pode ser próxima ao valor de fechamento do último dia de operação.
HIGH	Maior preço do ativo no dia.
LOW	Menor preço do ativo no dia.
CLOSE	Preço de fechamento do dia, valor corresponde à última operação. Operações terminam às 17:00h.
TICKVOL	Volume de operações, não leva em conta o volume de ações de cada, apenas a quantidade total de operações.
VOL	Volume de ações negociadas no dia.
SPREAD	Valor fracionário oriundo do desdobramento das ações. Ocorre quando uma empresa divide suas ações com finalidade de aumentar a circulação de papéis e diminuir o preço unitário.

Fonte: SOBRAL (2025).

Figura 1 – Representação dos períodos utilizados para treinamento, validação e teste, com suas respectivas durações em dias.



Fonte: SOBRAL (2025).

O segundo conjunto de dados, também utilizado neste trabalho e nos estudos mencionados anteriormente, é composto por informações dos preços das ações, as mesmas do *dataset* anterior, com intervalos de 15 minutos, ao longo de um período

de 40 dias. Esses dias correspondem exatamente aos mesmos 40 dias do conjunto de testes do primeiro *dataset*. Esse conjunto foi utilizado para simular estratégias de *day trading*, com base nas previsões fornecidas pelos modelos avaliados. A tabela 2 indica como esses dados eram constituídos originalmente

Tabela 2 – Variáveis originais do segundo *dataset*

Coluna	Significado
<i>DATE</i>	Data a que os dados se referem
<i>TIME</i>	Hora do dia (ex: 10:15:00)
<i>CLOSE</i>	Preço de fechamento da ação daquele determinado intervalo de 15 minutos

Fonte: O autor (2025).

3.1.2 Tratamento dos dados

Como mencionado anteriormente as colunas *TICKVOL*, *VOL* e *SPREAD* originais do primeiro *dataset* foram removidas por não agregarem para o objetivo e resultados deste trabalho. Foram adicionados dados referentes aos cinco dias anteriores ao dia atual, como o preço de abertura, de máxima e de mínima de cada dia. Além disso, foram adicionados indicadores técnicos muito comuns na análise do mercado financeiro que são a *EMA* (*Exponential Moving Average*) e as Bandas de *Bollinger* (BB).

A *EMA* é uma média ponderada dos preços de um ativo ao longo do tempo, onde os preços mais recentes têm maior peso. Isso a torna mais sensível a mudanças recentes no mercado. Ela é amplamente utilizada para identificar tendências e como gatilho para compra e venda de ativos no mercado financeiro [14]. Neste trabalho, o período utilizado para o cálculo da *EMA* foi de 5 dias.

Já as Bandas de *Bollinger* são um indicador técnico de análise utilizado para medir a volatilidade do mercado e identificar potenciais pontos de entrada e saída de operações [15]. Elas são compostas por três linhas: uma média móvel central, uma banda superior e uma banda inferior. Neste estudo, utilizou-se uma média móvel simples de 5 dias como base, e as bandas foram definidas como dois desvios padrão acima e abaixo dessa média. O indicador foi aplicado a quatro colunas de preço do ativo: *open*, *high*, *low* e *close*. Isso permitiu capturar a variação de volatilidade de forma mais completa ao longo dessas diferentes métricas de preço.

3.2 MODELOS

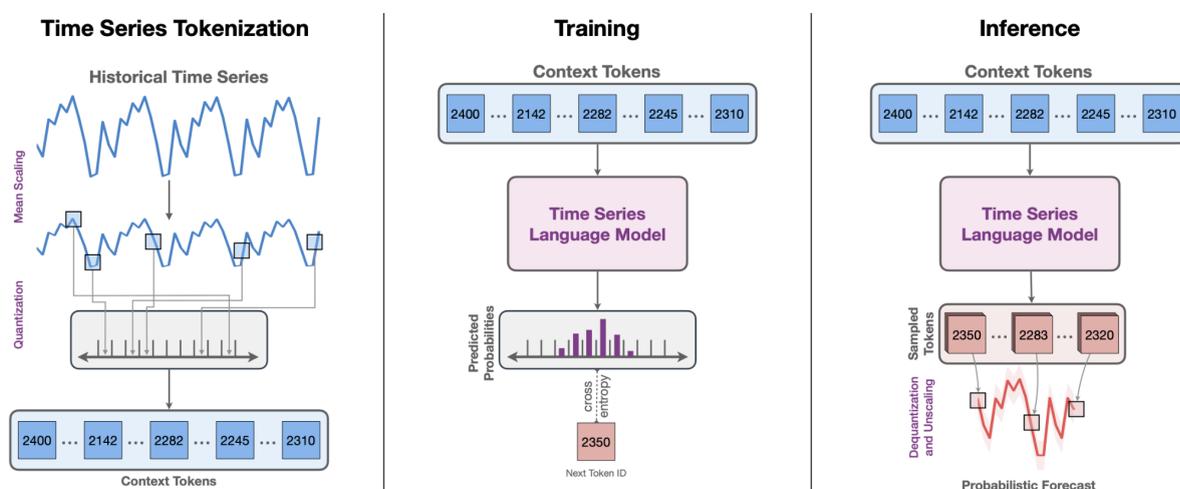
3.2.1 *Foundation models*

Foundation models são modelos de aprendizado profundo treinados em larga escala e com dados diversos, inclusive sintéticos, projetados para serem adaptáveis a diferentes tarefas com pouca ou nenhuma personalização. Esses modelos são amplamente utilizados em áreas como processamento de linguagem natural e visão computacional, e mais recentemente vêm sendo aplicados também em séries temporais [2].

3.2.2 *Chronos*

Chronos é um modelo de base univariado, desenvolvido pela Amazon [1] e voltado para tarefas de previsão de séries temporais. O termo univariado refere-se ao fato de que o modelo realiza previsões com base em uma única variável alvo por vez, como o preço de máxima diária da ação. Esse modelo transforma séries temporais em tokens por meio de técnicas de escala e quantização. O aprendizado é realizado com base em uma função de perda de entropia cruzada, permitindo que o modelo capture padrões complexos nos dados [1].

Uma vez treinado, o *Chronos* é capaz de gerar previsões probabilísticas, simulando diversos possíveis cenários futuros com base no histórico observado. Seu treinamento foi realizado em um grande volume de séries temporais públicas, complementado por dados sintéticos gerados via processos gaussianos [1]. Essa abordagem permite que o *Chronos* opere tanto em modo *zero-shot* quanto com *fine-tuning*, sendo uma opção promissora para domínios que exigem flexibilidade e robustez preditiva, como o mercado financeiro. A figura 2 ilustra o processo por trás do modelo desenvolvido pela Amazon.

Figura 2 – Visão geral do *Chronos*

Fonte: AMAZON (2025).

3.2.3 TimesFM

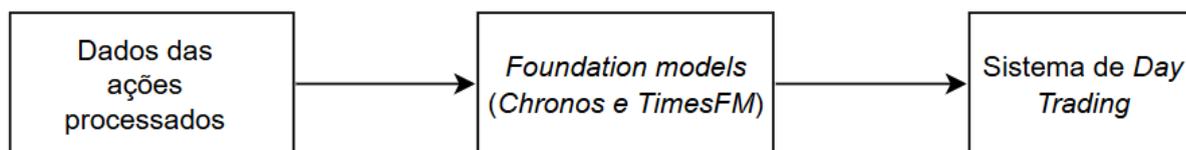
TimesFM também é um modelo de base univariado. Foi desenvolvido pela Google [6] especificamente para previsão de séries temporais. O modelo foi treinado do zero em um volume de dados temporais, composto por séries reais e dados sintéticos.

O *TimesFM* foi projetado para oferecer desempenho competitivo em modo *zero-shot*, ou seja, sem a necessidade de retreinamento para novos conjuntos de dados. O modelo é capaz de lidar com diferentes comprimentos de histórico, horizontes de previsão e granularidades temporais, apresentando resultados próximos aos de modelos supervisionados treinados individualmente para cada tarefa. Além disso, o *TimesFM* é relativamente leve, com cerca de 200 milhões de parâmetros, e visa oferecer uma alternativa prática e eficiente para aplicações de previsão em larga escala [6].

3.3 SISTEMA

A estrutura do sistema adotado neste trabalho segue a mesma utilizada por Albuquerque Filho [10] e Sobral [9], diferenciando-se apenas pelos modelos empregados na etapa de predição dos valores de máxima e mínima diária. A figura 3 ilustra todo o processo que o sistema faz.

Figura 3 – Visão geral do sistema



Fonte: O autor (2025).

O sistema desenvolvido neste trabalho recebe como entrada os dados das ações, realiza o pré-processamento conforme descrito na seção 3.1.2 e os utiliza nos modelos *Chronos* e *TimesFM* para a geração das previsões de máximas e mínimas diárias. Além disso, calcula-se o limiar de incerteza com base na mesma metodologia empregada por Sobral [9], e todas essas informações são então repassadas ao sistema de *Day Trading* proposto por Albuquerque Filho [10], responsável pela simulação das operações intra diárias.

3.4 FINE TUNING NO CHRONOS

Os modelos utilizados neste trabalho, conforme descrito na seção 3.2, apresentam algumas limitações importantes. Em primeiro lugar, são modelos univariados, ou seja, foram treinados para prever apenas uma variável de interesse por vez. Além disso, na configuração *zero-shot*, não é possível incorporar covariáveis, variáveis auxiliares que poderiam melhorar a qualidade das previsões, como o preço de abertura, as máximas e mínimas dos últimos cinco dias, a média móvel exponencial (*EMA*) e as bandas de *Bollinger*. A ausência dessas informações complementares impacta negativamente o desempenho dos modelos em tarefas de previsão mais complexas, como é o caso do mercado financeiro, onde existem inúmeras métricas importantes e que podem impactar muito na predição.

É justamente nesse contexto que o *fine-tuning* se torna relevante. *Fine-tuning* é uma técnica que consiste em adaptar um modelo previamente treinado para uma tarefa específica, utilizando um conjunto de dados menor e focado no novo domínio. Isso é feito reaproveitando os conhecimentos gerais adquiridos no treinamento inicial e ajustando apenas suas camadas finais ou parâmetros selecionados, o que torna o processo mais rápido e econômico do que treinar um modelo do zero [16].

No caso do *Chronos*, a vantagem do *fine-tuning* não se limita apenas a adaptar o modelo para o contexto específico. Ao fazer *fine tuning* você consegue incorporar covariáveis tanto no momento do retreinamento quanto no da predição. Isso aumenta muito o desempenho do modelo nesse contexto do mercado financeiro em que as covariáveis são de extrema importância para a realização da predição.

Por essas razões, foi realizado o processo de *fine-tuning*, utilizando os mesmos dados de treinamento empregados no modelo *Random Forest* para realizar o retreinamento do modelo de base e assim torná-lo mais específico ao contexto da previsão de preços no mercado financeiro. Nesse processo, também foram incorporadas como covariáveis os dados processados descritos na seção 3.1.2, tornando o modelo mais sensível às particularidades dos dados financeiros analisados.

Nesse processo foi utilizado o *AutoGluon*, que é uma *framework* de aprendizado de máquina *open source* desenvolvida pela Amazon, com o objetivo de automatizar o processo de criação e ajuste de modelos de *machine learning* [17]. A partir dele pode-se incorporar todas as covariáveis no retreinamento [18], e assim, melhorar muito o desempenho do modelo nas predições.

3.5 INCERTEZA

Seguindo a linha de Sobral [9], foi realizada uma análise sobre como o uso da incerteza influencia os resultados em operações de *day trading*, avaliando se sua utilização contribui para o aumento do retorno acumulado e a redução do máximo *drawdown*.

Essa análise foi conduzida exclusivamente com o modelo *Chronos* após o processo de *fine-tuning*, por ser o único capaz de fornecer estimativas de incerteza consistentes. Nos modelos aplicados em modo *zero-shot*, observou-se um aumento excessivo da incerteza à medida que os dias de previsão avançavam, o que inviabilizou a realização de uma análise confiável nesses casos.

3.5.1 Cálculo da incerteza

O cálculo da incerteza utilizando o *Chronos* é diferente da abordagem para o cálculo adotada por Sobral no modelo *Random Forest*, que foi calculada a partir do desvio padrão das previsões geradas por todas as árvores da floresta para os valores

mínimo e máximo estimados [9].

Como mencionado na seção 3.2.2, o *Chronos* é capaz de gerar previsões probabilísticas simulando diversos possíveis cenários futuros com base no histórico observado. Isso permite ao modelo não apenas prever um valor “médio” esperado (como em uma previsão pontual), mas também estimar intervalos de confiança em torno dessa previsão [1]. Esses intervalos são chamados de *quantiles* e a partir dele foi calculada a incerteza diária.

Durante a etapa de predição diária, foram utilizados três níveis de *quantiles*: 10%, 50% e 90%. O *quantile* de 10% representa o valor o qual há 10% de chance de o valor real ser menor que esse limite; o de 50% corresponde à mediana da previsão, isto é, o valor mais provável; e o de 90% indica que há 90% de chance de o valor real ser inferior a esse limite.

Com base nesses *quantiles*, a incerteza foi calculada como a diferença entre os valores dos quantis de 90% e 10%. Esse intervalo representa uma faixa de confiança de 80%, indicando que, com alta probabilidade, o valor real estará contido dentro desse intervalo de incerteza. E foi adotado o *quantile* de 50% como sendo a previsão realizada para as máximas e mínimas diárias.

3.5.2 Uso da incerteza

Conforme descrito por Sobral, além da incerteza diária calculada anteriormente, é necessário estabelecer um valor de referência para qualificar a incerteza como alta ou baixa. Para isso, foi utilizada a abordagem de validação, que consiste em utilizar um conjunto de validação como parâmetro de referência para avaliar as incertezas futuras do conjunto de testes. Essa abordagem permite estabelecer um limite de tolerância para a incerteza, possibilitando a qualificação da incerteza como alta ou baixa em relação ao valor de referência [9].

Para obter um referencial de incerteza média, foram consideradas as previsões de incerteza dos 40 dias pertencentes ao conjunto de validação. Com base nesses valores médios, construiu-se um intervalo com limites definidos pela maior e menor incerteza observada. Esse intervalo foi dividido em 20 segmentos de igual tamanho [9]. E a partir desses intervalos foi avaliado qual o melhor valor de incerteza para diminuir o máximo *drawdown* sem gerar grandes impactos no ganho de capital.

Durante a execução do Sistema de *Day Trade*, ao longo dos dias do conjunto de testes, a incerteza diária é avaliada, e caso o valor diário exceda o limite definido pelo usuário, o sistema não realizará operações naquele dia, classificando-o como um dia de risco.

A seção 4.2 mostra os resultados práticos da aplicação desta técnica, onde os segmentos são representados pela porcentagem de incerteza e em negrito está descrito o melhor valor de incerteza para se ter um balanço entre menor *drawdown* e maior ganho de capital.

3.6 DAY TRADING

O sistema de *day trading* adotado neste projeto foi baseado na proposta desenvolvida por Albuquerque Filho [10], a qual, por sua vez, teve como referência o trabalho de Martinez [12]. Esse sistema opera a partir do segundo conjunto de dados descrito na seção 3.1.2, que contém informações intra diárias dos preços das ações em intervalos de 15 minutos. A cada novo intervalo, o sistema avalia as condições do mercado e decide se deve realizar uma compra, efetuar uma venda ou manter a posição atual dos ativos.

Para a realização da simulação, optou-se por desconsiderar custos operacionais típicos de corretoras, como taxas de compra e venda, bem como o imposto de renda incidente sobre operações de venda. O capital inicial adotado foi de R\$500.000, seguindo o mesmo valor utilizado por Sobral [9], de modo a manter condições equivalentes e permitir uma comparação direta entre os resultados.

3.6.1 Regras para compra e venda dos ativos

Ao final de cada intervalo de 15 minutos, o sistema avalia se o preço de fechamento daquele período excede o valor máximo ou fica abaixo do valor mínimo previsto pelos modelos de base para o respectivo dia. Caso uma dessas condições seja atendida, o sistema executa automaticamente uma operação de venda ou de compra, respectivamente. Desta forma, é possível que não haja nenhuma operação em um determinado dia, caso os preços dos intervalos fiquem sempre entre a faixa de predição, ou seja, entre a máxima e a mínima previstas.

Cabe destacar que, por se tratar de um sistema de *day trading*, toda operação de entrada, seja de compra ou de venda, deve obrigatoriamente ser seguida por

uma operação de saída, ainda que isso implique em prejuízo. Caso a condição para a realização da saída não seja atendida durante o dia, o sistema executa a operação de saída no último intervalo disponível. Essa regra operacional também foi adotada no estudo de Sobral [9].

A imagem 4 ilustra essas regras de negociações. Onde \min_{Pred} e \max_{Pred} são os valores de mínimo e de máximo preditos pelo modelo e fecho é o valor de fechamento do ativo no intervalo de 15 minutos.

Figura 4 – Regras de negociações

1. Comprar quando $\text{fecho} \leq \min_{\text{Pred}}$, vender quando $\text{fecho} \geq \max_{\text{Pred}}$;
2. Comprar quando $\text{fecho} \leq \min_{\text{Pred}}$, vender no último minuto do dia;
3. Comprar quando $\text{fecho} \leq \min_{\text{Pred}}$, vender no preço de stop-loss;
4. Vender quando $\text{fecho} \geq \max_{\text{Pred}}$, comprar quando $\text{fecho} \leq \min_{\text{Pred}}$;
5. Vender quando $\text{fecho} \geq \max_{\text{Pred}}$, comprar no último minuto do dia;
6. Vender quando $\text{fecho} \geq \max_{\text{Pred}}$, comprar no preço de stop-loss;

Fonte – SOBRAL (2025).

3.6.2 Controle de riscos

Além da utilização da métrica de incerteza no modelo *Chronos* após o *fine-tuning*, conforme descrito na seção 3.5.2, este trabalho também incorpora outra técnica amplamente utilizada em sistemas de *day trading* para mitigar perdas significativas: o *stop-loss*. Essa estratégia consiste em uma ordem com instruções para fechar uma posição comprada ou vendida quando o preço atingir um determinado nível, com o objetivo de limitar perdas ou garantir lucro [19].

No contexto deste estudo, o mecanismo de *stop-loss* foi implementado com base na abordagem proposta por Albuquerque Filho [10]. Especificamente, se o ativo se movimentar no sentido contrário do predito e apresentar uma diferença de 2% o sistema encerra a posição automaticamente. O que significa que operações de compra eram encerradas automaticamente em caso de queda superior a 2%, enquanto operações de venda eram encerradas em caso de alta superior a esse mesmo percentual [9]. Esse procedimento está detalhado nos itens 3 e 6 da figura 4.

3.6.3 Drawdown

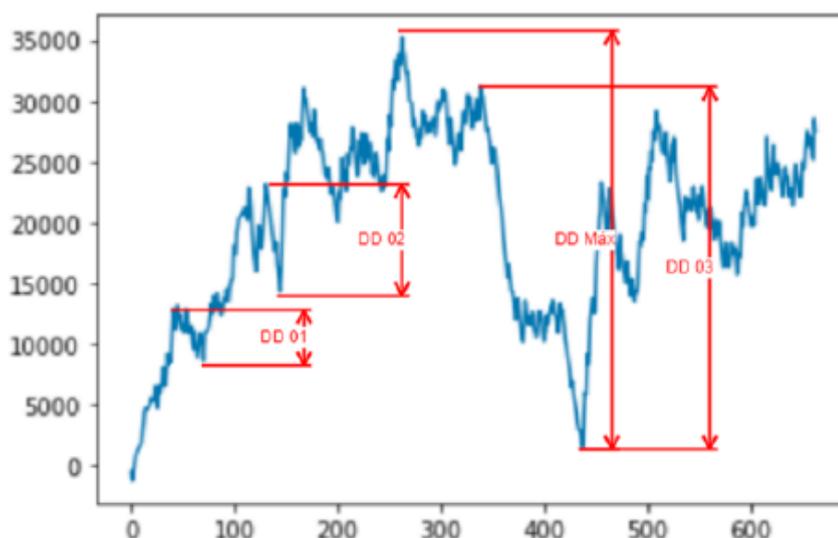
Um *drawdown* refere-se ao declínio percentual desde um pico até um ponto mais baixo em uma série temporal de preços ou patrimônio, representando a magnitude de uma perda em um intervalo específico. Já o máximo *drawdown* (MDD) corresponde à maior queda acumulada observada entre um pico e o subsequente ponto mais baixo durante um período definido [23]. Em outras palavras, é a pior retração enfrentada por um investimento antes de atingir um novo valor máximo.

O *drawdown* é utilizado para quantificar o risco de queda durante ciclos adversos, sendo útil para gestores de fundos e investidores que desejam entender o risco máximo de perda. Já o máximo *drawdown* é amplamente utilizado como métrica de risco, especialmente em investimentos de alta volatilidade.

No escopo deste trabalho será utilizado a incerteza como principal mecanismo para redução do máximo *drawdown*. Em alguns casos o uso dessa técnica pode gerar um menor montante final, mas para investidores conservadores pode ser uma boa estratégia pois evita que haja uma grande queda no capital.

A figura 5 exemplifica como identificar os *drawdowns* em um gráfico, bem como o máximo *drawdown*.

Figura 5 – Exemplos de *Drawdowns*



Fonte – ALBUQUERQUE FILHO (2021).

3.7 COMPARAÇÃO COM O *RANDOM FOREST*

A comparação entre os resultados obtidos com as previsões dos modelos de base e aqueles alcançados com o modelo *Random Forest* é direta, pois não houve mudanças significativas no sistema de *day trading* proposto pelos trabalhos mencionados. No estudo de Sobral [9], foi proposta uma métrica de avaliação para comparar o desempenho do *Random Forest* com e sem a aplicação da incerteza nas decisões. Essa métrica, denominada *Score final*, foi definida da seguinte forma:

Score final = 6 x Montante final + 3 x Taxa de sucesso - 2 x Máximo *Drawdown* [9]

Nessa fórmula, o Montante Final possui maior peso por refletir diretamente o retorno financeiro, enquanto a Taxa de Sucesso representa o percentual de operações lucrativas, e o Máximo *Drawdown* penaliza grandes perdas durante o período de simulação.

Neste trabalho, o *Score final* será adotado como principal métrica de comparação, com o objetivo de avaliar se os modelos de base oferecem desempenho superior ao *Random Forest* nas estratégias de *day trading*.

4 RESULTADOS

4.1 PREVISÕES DE MÁXIMA E MÍNIMA

Os primeiros resultados analisados dizem respeito às previsões dos valores de máxima e mínima diária das ações ao longo dos 40 dias que compõem o conjunto de testes, abrangendo as seis ações selecionadas neste estudo.

Como os modelos TimesFM e Chronos (tanto em zero-shot quanto com fine-tuning) são univariados, ou seja, realizam previsões de uma variável por vez, foram construídos dois gráficos por ação (um para a máxima e outro para a mínima) para cada modelo avaliado.

Já o modelo Random Forest, por outro lado, é multivariado e incorpora covariáveis durante o processo de treinamento e predição, o que contribuiu para seu desempenho mais robusto em alguns casos.

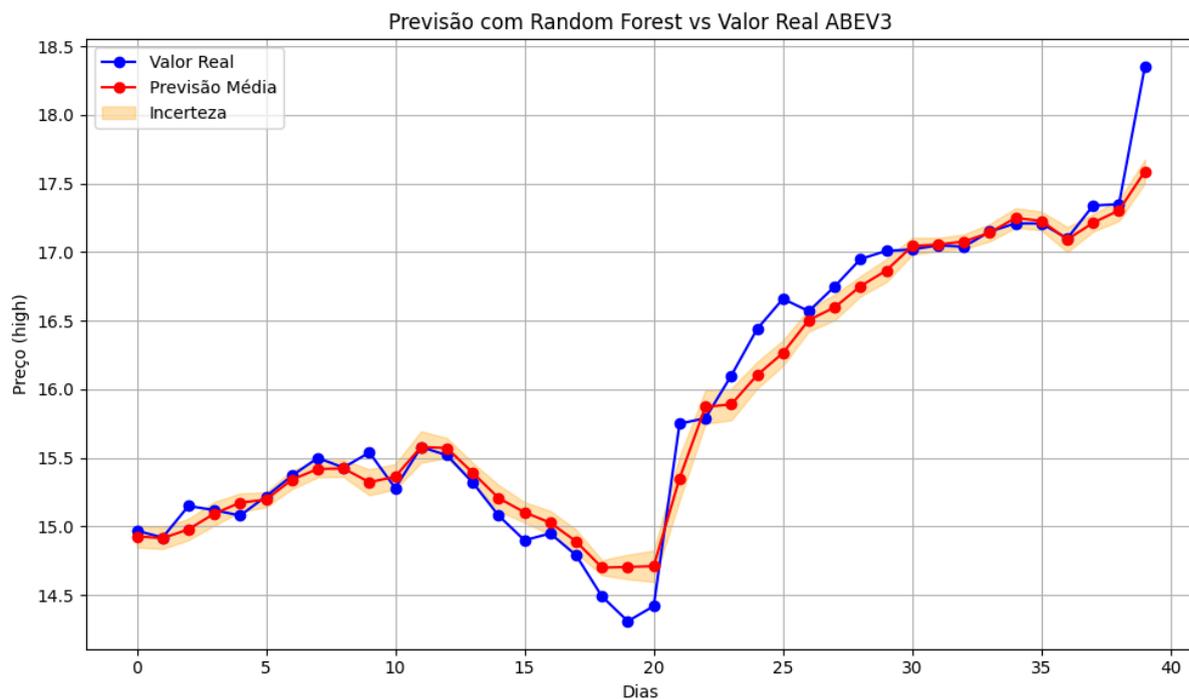
Isso resultou em um total de 48 gráficos apenas para esta etapa de análise preditiva. A fim de evitar repetição excessiva, será apresentada a seguir apenas uma amostra representativa desses resultados. Os gráficos completos podem ser consultados no Apêndice A.

4.1.1 Previsões com *Random Forest*

Conforme mencionado anteriormente, os resultados do modelo *Random Forest* utilizados neste trabalho foram obtidos a partir do estudo de Sobral [9]. No entanto, o trabalho original não apresentou visualizações gráficas das previsões realizadas por esse modelo. Para viabilizar uma comparação direta com os resultados dos modelos de base, este estudo construiu os gráficos correspondentes a partir dos dados fornecidos por Sobral, que estavam disponibilizados em formato digital (.pkl). Assim, embora os resultados numéricos tenham sido originalmente produzidos por Sobral, a elaboração dos gráficos comparativos foi conduzida exclusivamente neste trabalho.

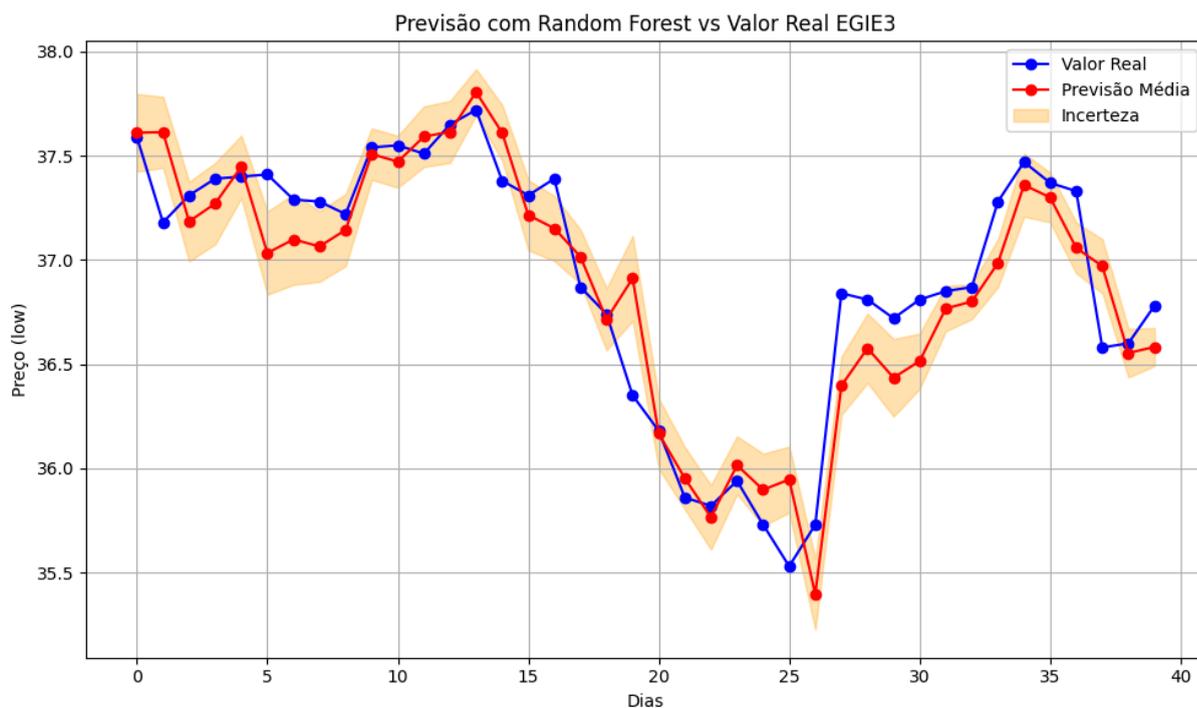
As figuras 6, 7 e 8 representam alguns resultados interessantes obtidos pelo *Random Forest* e ilustram bem como esse modelo com acesso à algumas métricas durante o treinamento, como as Bandas de *Bollinger*, obtiveram resultados muito positivos. Nos gráficos a linha azul representa o valor real, a linha vermelha representa a previsão média, e o intervalo amarelo representa o intervalo de incerteza para àquela previsão.

Figura 6 – Previsão do valor máximo diário da ação ABEV3 utilizando o modelo *Random Forest*



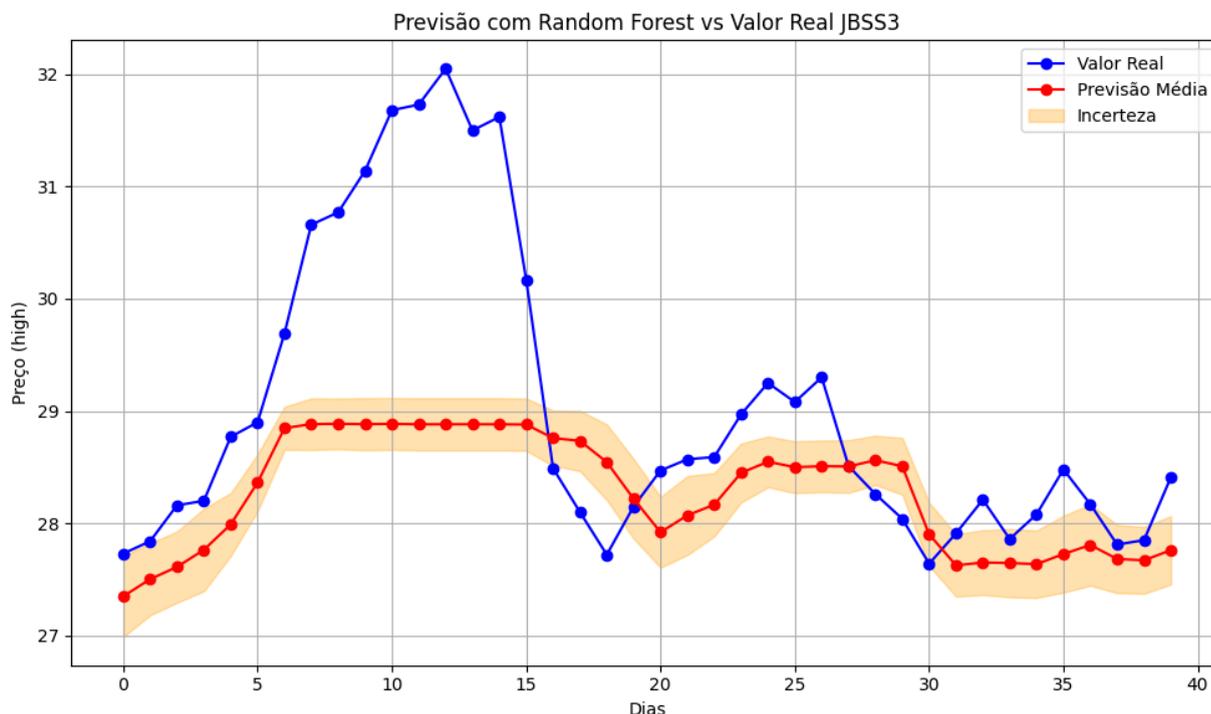
Fonte: O autor (2025).

Figura 7 – Previsão do valor mínimo diário da ação EGIE3 utilizando o modelo *Random Forest*



Fonte: O autor (2025).

Figura 8 – Previsão do valor máximo diário da ação JBSS3 utilizando o modelo *Random Forest*



Fonte: O autor (2025).

Observa-se que o modelo apresentou resultados bastante satisfatórios para os ativos ABEV3 e EGIE3. No entanto, o desempenho em relação à ação JBSS3 foi inferior, indicando uma menor precisão nas previsões.

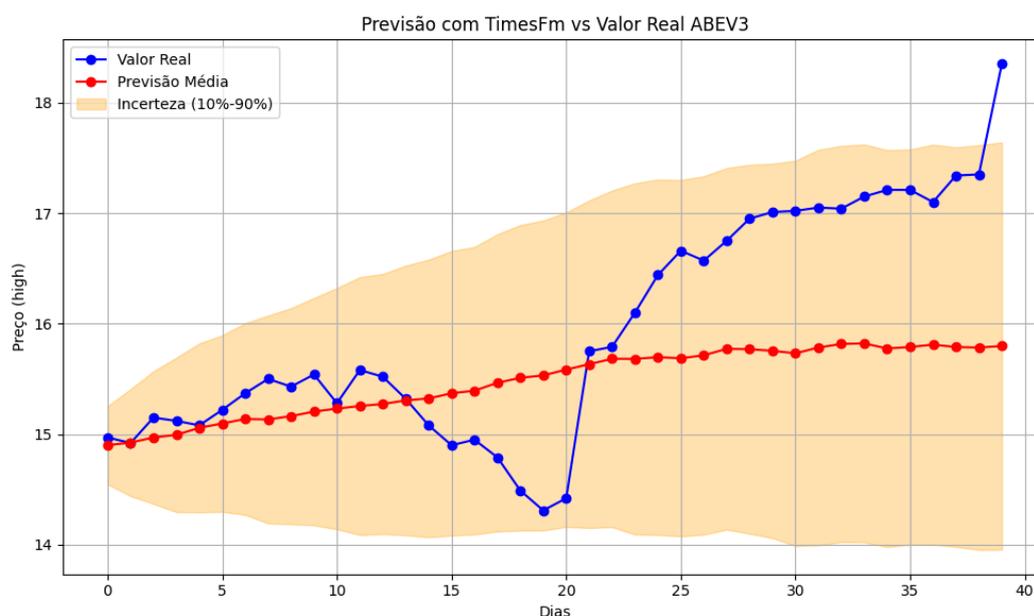
A alta repentina no preço das ações da JBSS3 pode ser atribuída à empresa ter registrado um lucro expressivo de R\$ 2 bilhões no primeiro trimestre de 2021 [21], além do anúncio, em 28/04/2021, do pagamento de R\$ 2,5 bilhões em dividendos [22], o que também impulsionou a valorização dos papéis. Esses acontecimentos reforçam a ideia de que prever os preços das ações com base apenas em dados históricos nem sempre é eficaz, já que o mercado financeiro é altamente volátil e fortemente influenciado por fatores externos e eventos inesperados.

Ainda assim, esse resultado parece ser um caso isolado, já que, conforme demonstrado nos demais gráficos disponíveis no Apêndice A, o modelo manteve um desempenho consistente e positivo nas outras ações analisadas.

4.1.2 Predições com *TimesFM*

As figuras 9, 10 e 11 ilustram o desempenho do *foundation model* desenvolvido pela Google, o *TimesFM*, aplicando-se aos mesmos casos utilizados anteriormente para a análise do modelo *Random Forest*. Essa comparação permite avaliar de forma direta a diferença de performance entre as abordagens.

Figura 9 – Previsão do valor máximo diário da ação ABEV3 utilizando o modelo *TimesFM*



Fonte: O autor (2025).

Figura 10 – Previsão do valor mínimo diário da ação EGIE3 utilizando o modelo *TimesFM*

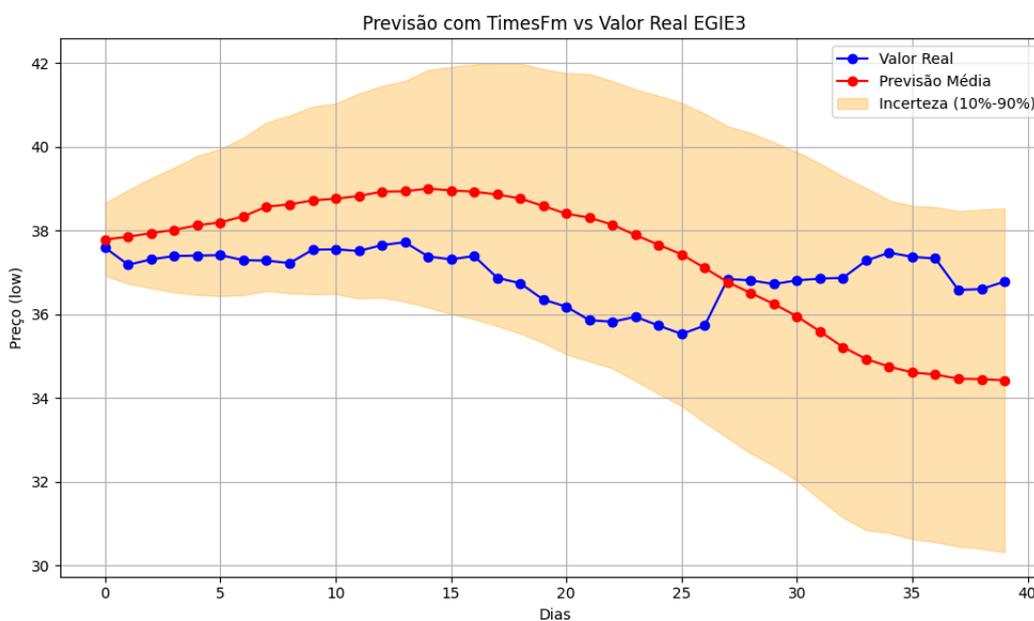
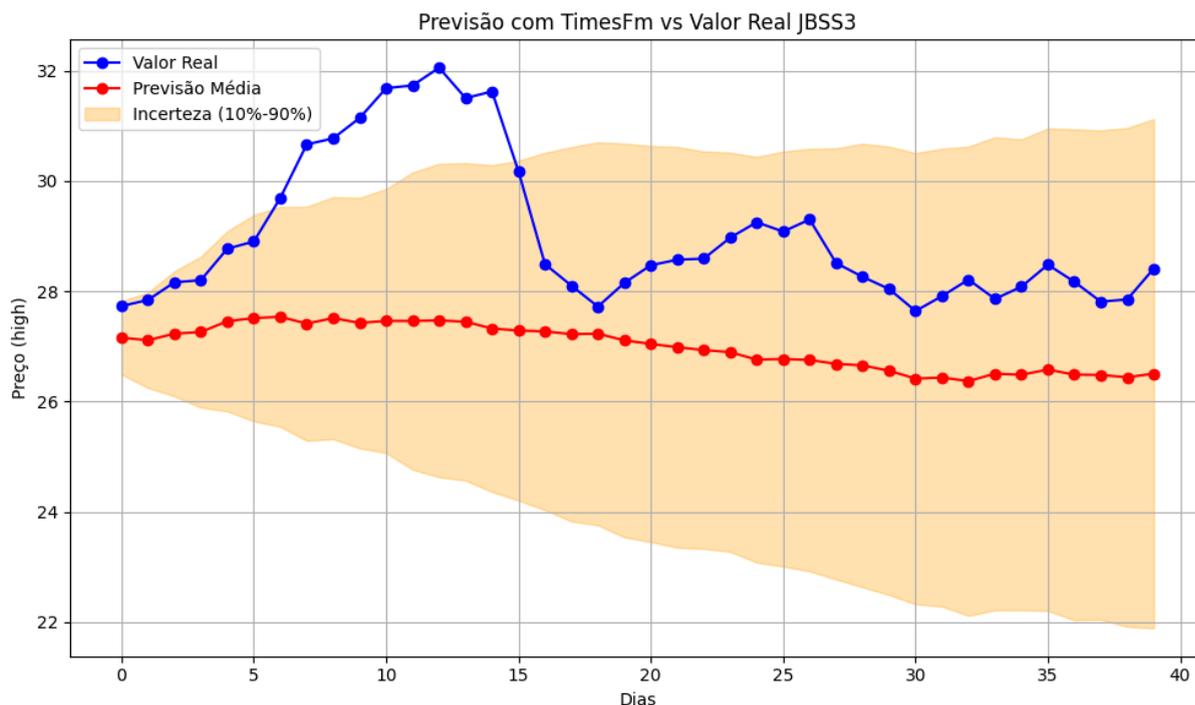


Figura 11 – Previsão do valor máximo diário da ação JBSS3 utilizando o modelo *TimesFM*



Fonte: O autor (2025).

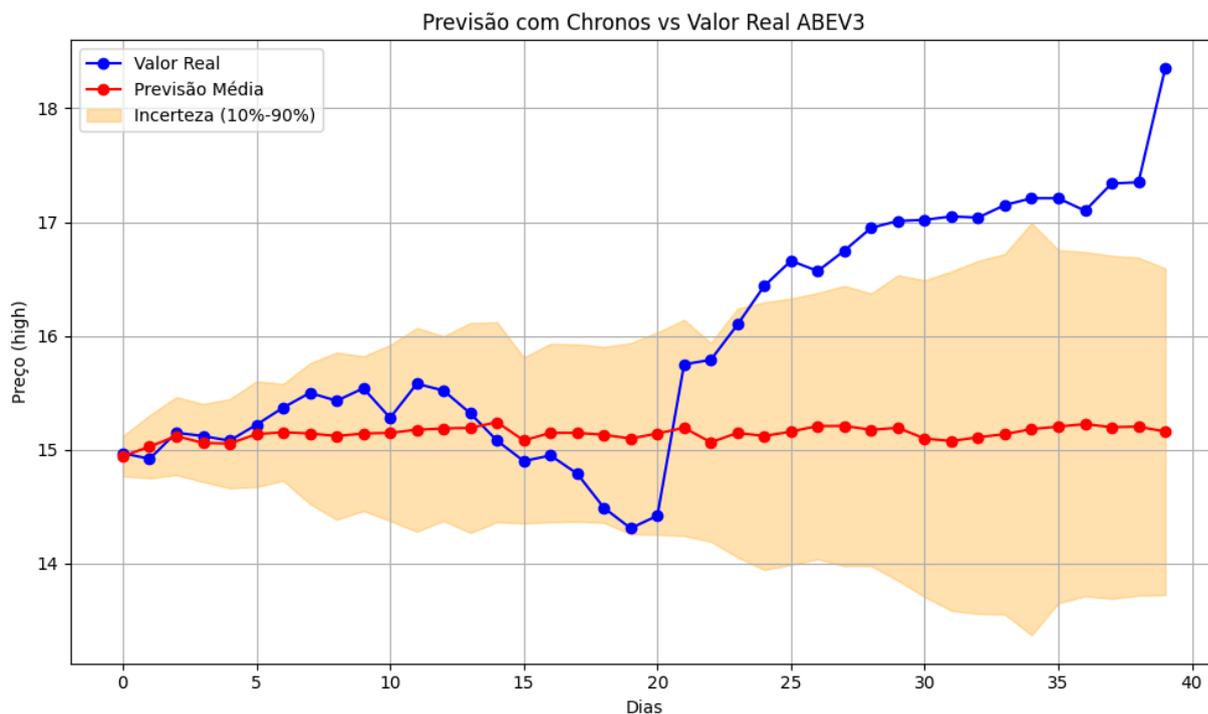
Percebe-se que o desempenho deste modelo de base foi significativamente inferior ao do *Random Forest*. As previsões apresentaram baixa variabilidade, sugerindo que o modelo teve dificuldade em reagir às oscilações reais da série. Já a incerteza associada aumentou progressivamente ao longo do tempo, o que inviabilizou a aplicação da análise de incerteza que será realizada posteriormente com o modelo *Chronos* ajustado via *fine-tuning*.

A principal justificativa para esse desempenho limitado está na incapacidade do modelo de incorporar covariáveis no processo de previsão. Dessa forma, o modelo se baseia unicamente na série histórica dos preços das ações, sem considerar métricas complementares que poderiam auxiliar no contexto preditivo, como a Média Móvel Exponencial (*EMA*) e as Bandas de *Bollinger*.

4.1.3 Previsões com *Chronos zero-shot*

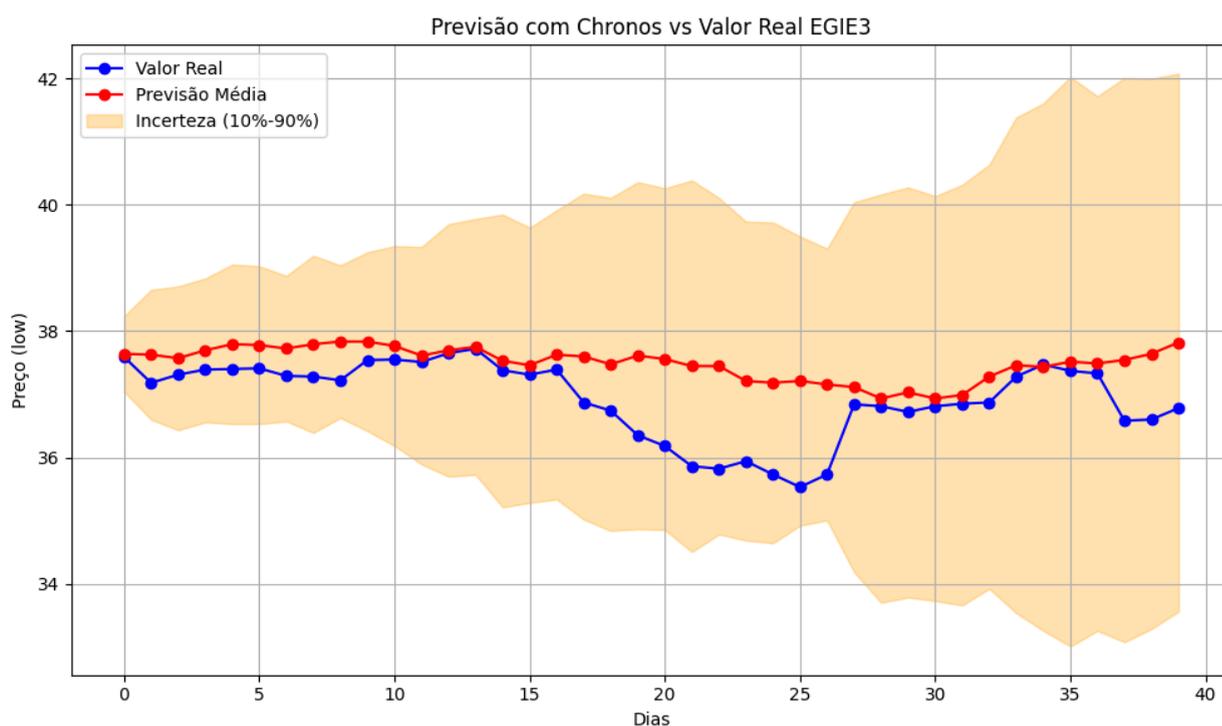
As figuras 12, 13 e 14 apresentam os resultados obtidos pelo modelo *Chronos* em modo *zero-shot*, aplicados aos mesmos contextos previamente analisados para os modelos *Random Forest* e *TimesFM*.

Figura 12 – Previsão do valor máximo diário da ação ABEV3 utilizando o modelo *Chronos* (*zero-shot*)



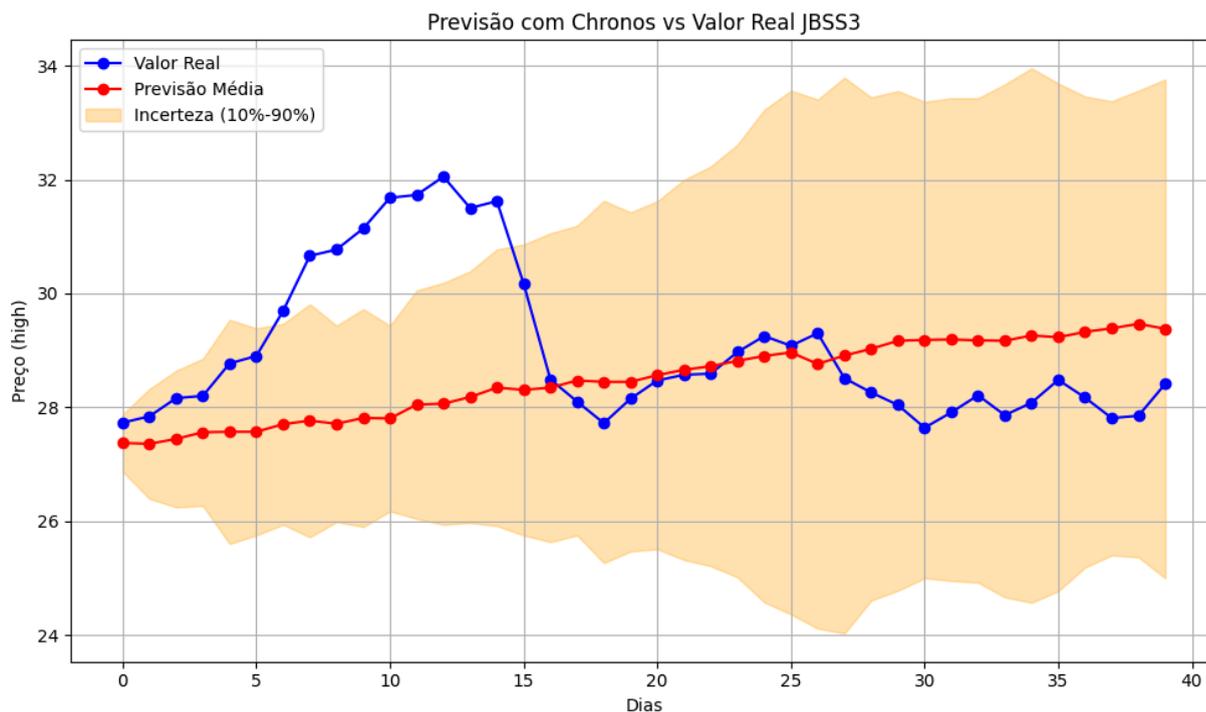
Fonte: O autor (2025).

Figura 13 – Previsão do valor mínimo diário da ação EGIE3 utilizando o modelo *Chronos* (*zero-shot*)



Fonte: O autor (2025).

Figura 14 – Previsão do valor máximo diário da ação JBSS3 utilizando o modelo *Chronos* (*zero-shot*)



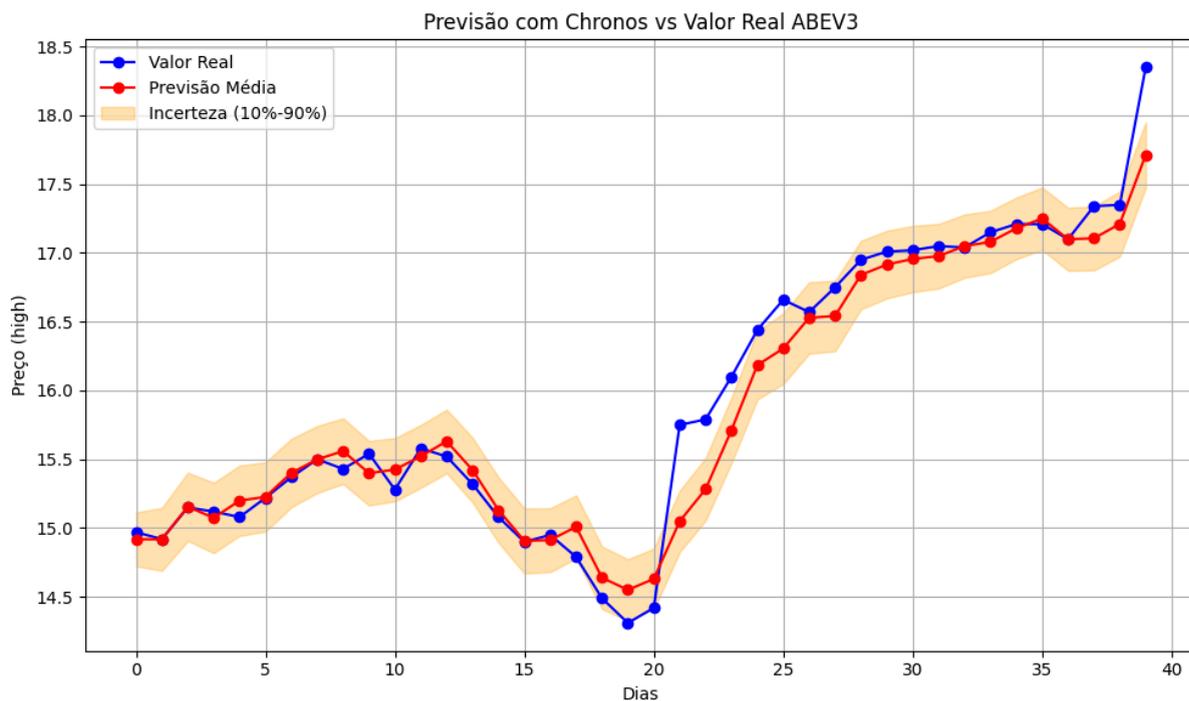
Fonte: O autor (2025).

Os resultados obtidos pelo *Chronos* em modo *zero-shot* são bastante semelhantes aos do *TimesFM* e, assim como este, significativamente inferiores aos alcançados pelo modelo *Random Forest*. Essa limitação pode ser atribuída à mesma razão discutida anteriormente: por serem modelos de base univariados, eles não têm acesso a covariáveis que fornecem contexto adicional essencial para a tarefa de previsão. No mercado financeiro, esse contexto é especialmente relevante, dada a alta volatilidade e a influência de múltiplos fatores sobre o comportamento dos preços.

4.1.4 Previsões com *Chronos* pós *Fine Tuning*

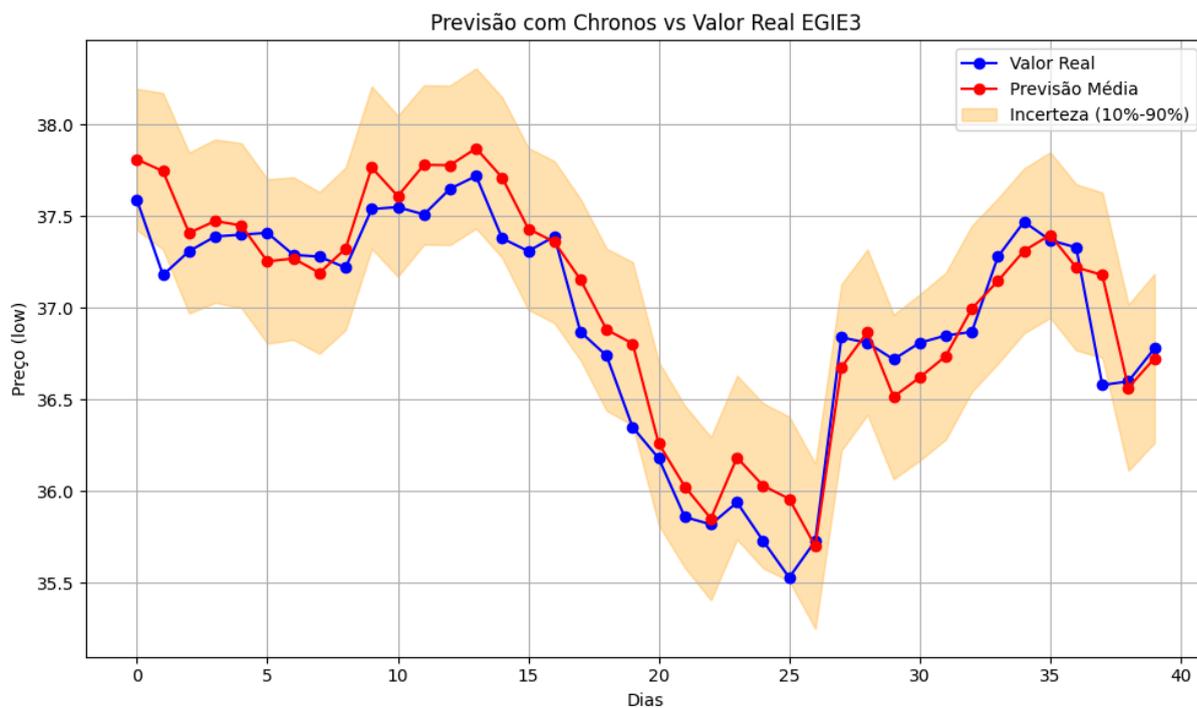
Diante do desempenho inferior dos modelos de base em modo *zero-shot* em relação ao *Random Forest*, optou-se por realizar o *fine-tuning* no modelo *Chronos*. Essa decisão se justifica pela possibilidade de incorporar covariáveis tanto durante o processo de reconfiguração do modelo quanto na etapa de predição, ampliando o contexto disponível para as previsões. As figuras 15, 16 e 17 ilustram os resultados dessa abordagem no mesmo contexto dos modelos anteriores.

Figura 15 – Previsão do valor máximo diário da ação ABEV3 utilizando o modelo *Chronos*

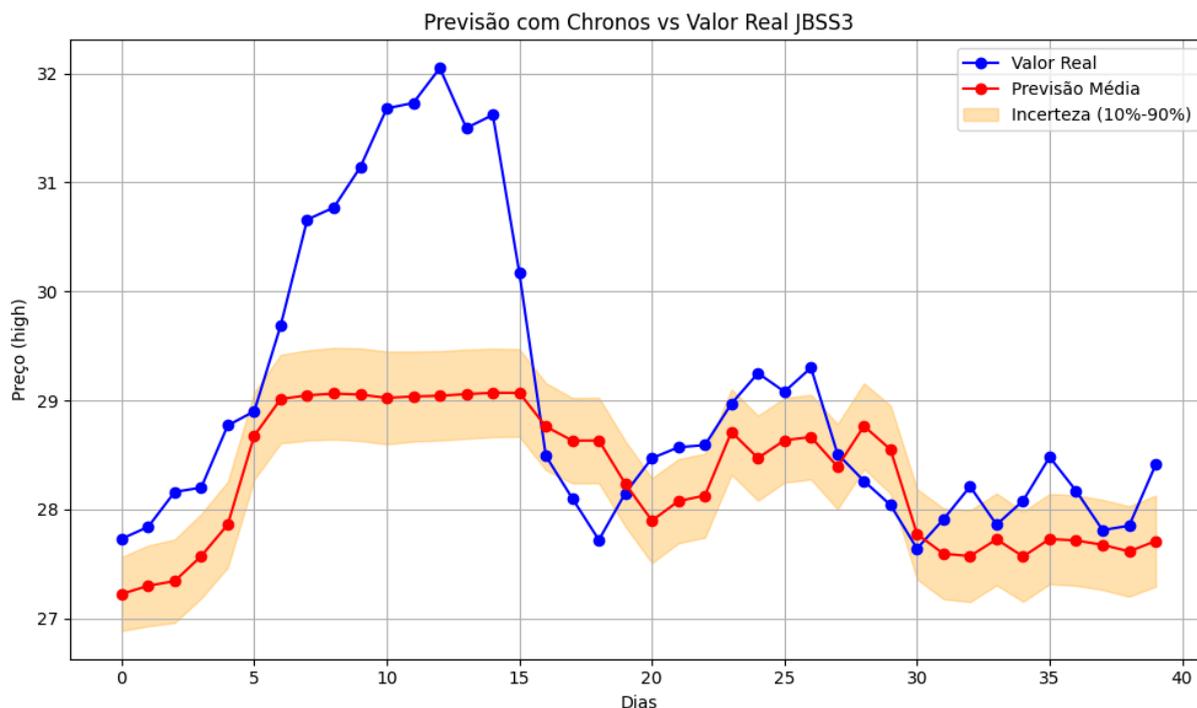


Fonte: O autor (2025).

Figura 16 – Previsão do valor mínimo diário da ação EGIE3 utilizando o modelo *Chronos*



Fonte: O autor (2025).

Figura 17 – Previsão do valor máximo diário da ação JBSS3 utilizando o modelo *Chronos*

Fonte: O autor (2025).

Fica evidente que, após a incorporação das covariáveis e o reprocessamento do modelo por meio do *fine-tuning* para o contexto específico do problema, o modelo *Chronos* passou a apresentar resultados significativamente mais positivos. Seu desempenho tornou-se comparável ao do *Random Forest* e superou muito os resultados obtidos pelos modelos de base em modo *zero-shot*, comprovando as hipóteses prévias sobre a importância das covariáveis.

4.2 SISTEMA DE *DAY TRADING*

Nesta subseção, serão apresentados e analisados os resultados obtidos na avaliação da incerteza e na simulação das operações de *day trading* ao longo de 40 dias.

4.2.1 Análise da incerteza

Conforme descrito na seção 3.5.2, a análise baseada na incerteza foi aplicada exclusivamente ao modelo *Chronos* após o processo de *fine-tuning*. Isso se deve ao fato de que, como exemplificado na seção 4.1, nos modelos de base em modo

zero-shot, a incerteza diária aumentava progressivamente ao longo do tempo, o que inviabiliza a aplicação consistente da metodologia proposta.

A seguir, são apresentadas tabelas com os resultados da análise de incerteza obtidos pelo modelo *Chronos*, juntamente com os resultados correspondentes do modelo *Random Forest* [9], permitindo uma comparação detalhada no contexto de cada uma das ações analisadas.

Tabela 3 – Análise da incerteza ABEV3 (*CHRONOS*)

Incerteza	Taxa de sucesso	MDD	Dias operados
5,00%	0,00%	0,852%	1
15,00%	0,00%	0,852%	1
25,00%	63,64%	1,563%	5
35,00%	53,26%	2,921%	13
45,00%	51,18%	6,334%	20
55,00%	54,12%	9,519%	24
65,00%	53,03%	9,077%	25
75,00%	59,75%	8,546%	33
85,00%	56,59%	9,524%	36
95,00%	59,60%	9,231%	40

Fonte: O autor (2025).

Tabela 4 – Análise da incerteza ABEV3 (*RANDOM FOREST*)

Incerteza	Taxa de sucesso	MDD	Dias operados
5,00%	100,00%	0,00%	1
15,00%	69,57%	2,4585%	9
25,00%	65,85%	2,7835%	17
35,00%	62,07%	6,2958%	27
45,00%	59,15%	6,4722%	35
55,00%	59,15%	6,4722%	35
65,00%	60,53%	6,4710%	39
75,00%	60,53%	6,4710%	39
85,00%	60,53%	6,4710%	39
95,00%	60,26%	6,4670%	40

Fonte: SOBRAL (2025).

Tabela 5 – Análise da incerteza BBDC4 (*CHRONOS*)

Incerteza	Taxa de sucesso	MDD	Dias operados
5,00%	50,00%	0,326%	1
15,00%	50,00%	0,326%	1
25,00%	40,00%	1,379%	4
35,00%	45,45%	3,664%	13
45,00%	48,57%	3,076%	20
55,00%	53,33%	2,466%	25
65,00%	52,08%	2,842%	28
75,00%	54,55%	2,670%	31
85,00%	57,38%	3,466%	34
95,00%	58,57%	4,122%	38

Fonte: O autor (2025).

Tabela 6 – Análise da incerteza BBDC4 (*RANDOM FOREST*)

Incerteza	Taxa de sucesso	MDD	Dias operados
5,00%	55,56%	1,9056%	5
15,00%	52,94%	2,6473%	20
25,00%	55,17%	2,4064%	34
35,00%	53,73%	4,7574%	40
45,00%	53,73%	4,7574%	40
55,00%	53,73%	4,7574%	40
65,00%	53,73%	4,7574%	40
75,00%	53,73%	4,7574%	40
85,00%	53,73%	4,7574%	40
95,00%	53,73%	4,7574%	40

Fonte: SOBRAL (2025).

Tabela 7 – Análise da incerteza EGIE3 (*CHRONOS*)

Incerteza	Taxa de sucesso	MDD	Dias operados
5,00%	50,00%	0,339%	1
15,00%	47,06%	1,235%	2
25,00%	66,67%	1,235%	8
35,00%	67,12%	1,235%	10
45,00%	63,46%	1,834%	15
55,00%	67,12%	2,584%	23
65,00%	66,23%	2,584%	27
75,00%	67,90%	2,584%	31
85,00%	63,35%	2,584%	39
95,00%	63,27%	2,584%	40

Fonte: O autor (2025).

Tabela 8 – Análise da incerteza EGIE3 (*RANDOM FOREST*)

Incerteza	Taxa de sucesso	MDD	Dias operados
5,00%	76,00%	0,6744%	4
15,00%	75,86%	1,8302%	16
25,00%	77,57%	3,1077%	33
35,00%	77,69%	3,1050%	39
45,00%	78,05%	3,1062%	40
55,00%	78,05%	3,1062%	40
65,00%	78,05%	3,1062%	40
75,00%	78,05%	3,1062%	40
85,00%	78,05%	3,1062%	40
95,00%	78,05%	3,1062%	40

Fonte: SOBRAL (2025).

Tabela 9 – Análise da incerteza ITUB4 (*CHRONOS*)

Incerteza	Taxa de sucesso	MDD	Dias operados
5,00%	100,00%	0,00%	1
15,00%	100,00%	0,00%	1
25,00%	80,00%	0,320%	3
35,00%	63,64%	2,370%	6
45,00%	56,25%	2,511%	10
55,00%	54,84%	3,595%	21
65,00%	55,00%	4,645%	26
75,00%	50,00%	4,645%	31
85,00%	46,30%	6,253%	38
95,00%	46,43%	7,113%	40

Fonte: O autor (2025).

Tabela 10 – Análise da incerteza ITUB4 (*RANDOM FOREST*)

Incerteza	Taxa de sucesso	MDD	Dias operados
5,00%	37,50%	4,3379%	6
15,00%	53,57%	4,0018%	16
25,00%	48,57%	4,6100%	22
35,00%	50,00%	5,3092%	24
45,00%	47,73%	8,4979%	29
55,00%	49,02%	8,9243%	35
65,00%	50,94%	8,1393%	37
75,00%	50,91%	7,7313%	39
85,00%	51,79%	7,4673%	40
95,00%	51,79%	7,4673%	40

Fonte: SOBRAL (2025).

Tabela 11 – Análise da incerteza JBSS3 (*CHRONOS*)

Incerteza	Taxa de sucesso	MDD	Dias operados
5,00%	66,67%	0,625%	1
15,00%	66,67%	0,625%	1
25,00%	50,00%	2,976%	3
35,00%	42,86%	4,136%	9
45,00%	59,38%	7,270%	19
55,00%	56,76%	7,270%	24
65,00%	53,49%	7,270%	28
75,00%	51,06%	7,270%	31
85,00%	51,02%	7,270%	33
95,00%	52,54%	9,116%	40

Fonte: O autor (2025).

Tabela 12 – Análise da incerteza JBSS3 (*RANDOM FOREST*)

Incerteza	Taxa de sucesso	MDD	Dias operados
5,00%	0,00%	0,0000%	0
15,00%	0,00%	0,0000%	0
25,00%	0,00%	0,0000%	0
35,00%	0,00%	0,0000%	0
45,00%	0,00%	0,0000%	0
55,00%	57,89%	4,7980%	15
65,00%	52,00%	5,3644%	20
75,00%	47,06%	7,2278%	27
85,00%	42,86%	9,4208%	33
95,00%	47,92%	9,4208%	37

Fonte: SOBRAL (2025).

Tabela 13 – Análise da incerteza PETR4 (*CHRONOS*)

Incerteza	Taxa de sucesso	MDD	Dias operados
5,00%	66,67%	0,213	1
15,00%	66,67%	0,213	1
25,00%	66,67%	0,213	1
35,00%	60,00%	0,631	2
45,00%	66,67%	2,256	6
55,00%	62,86%	2,897	15
65,00%	61,36%	3,349	20
75,00%	59,15%	3,349	27
85,00%	59,49%	3,571	33
95,00%	61,70%	5,868	40

Fonte: O autor (2025).

Tabela 14 – Análise da incerteza PETR4 (*RANDOM FOREST*)

Incerteza	Taxa de sucesso	MDD	Dias operados
5,00%	63,64%	6,7612%	15
15,00%	60,76%	7,0319%	33
25,00%	56,82%	10,0402%	39
35,00%	57,30%	9,3157%	40
45,00%	57,30%	9,3157%	40
55,00%	57,30%	9,3157%	40
65,00%	57,30%	9,3157%	40
75,00%	57,30%	9,3157%	40
85,00%	57,30%	9,3157%	40
95,00%	57,30%	9,3157%	40

Fonte: SOBRAL (2025).

Esses resultados apontam, como ressaltado por Sobral [9], que há uma tendência de redução no máximo *drawdown* à medida que o critério de incerteza se torna mais restritivo. Isso indica que a adoção de limites de incerteza mais conservadores pode ajudar a evitar perdas significativas de capital. Além disso, em grande parte dos casos, nota-se uma associação entre a taxa de sucesso das operações e o intervalo de incerteza utilizado. Contudo, essa relação não é completamente consistente, pois alguns intervalos específicos apresentaram variações inesperadas na taxa de sucesso.

Essas oscilações sugerem que o efeito da incerteza sobre os resultados pode depender de outros elementos, como a volatilidade da ação ou o comportamento do mercado durante o período analisado. Assim, a definição do intervalo ideal de incerteza deve buscar um equilíbrio entre a redução de risco (via *drawdown*), a manutenção do desempenho operacional (refletido na taxa de sucesso e na frequência de operações) e a maximização dos retornos financeiros.

4.2.2 Operações de *day trading*

Nesta seção, são apresentadas tabelas comparativas entre os resultados obtidos na simulação de 40 dias de *day trading* utilizando as previsões dos modelos de base e do *Random Forest*. Cada tabela inclui os seguintes indicadores para a ação correspondente: capital final, taxa de sucesso, máximo *drawdown* e *score* final, conforme definido na metodologia.

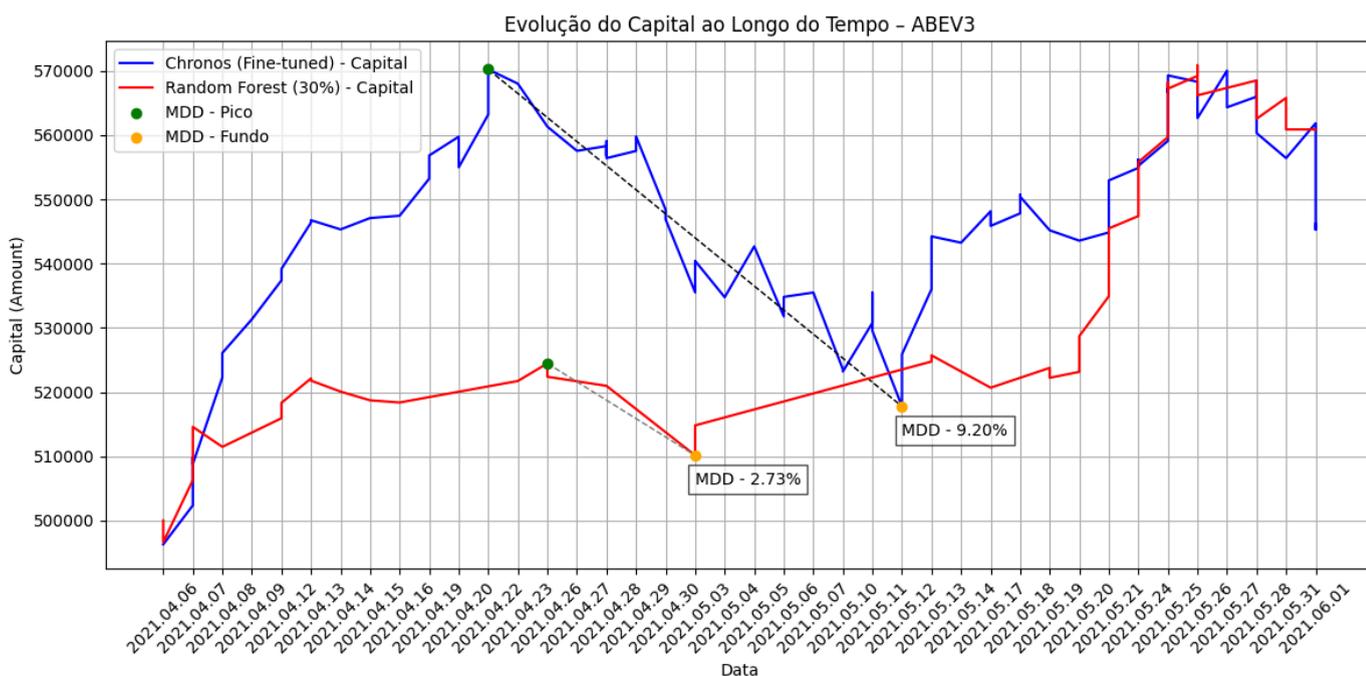
Além disso, cada subseção trará um gráfico representativo contendo o melhor desempenho alcançado pelas previsões da *Random Forest* e o melhor desempenho alcançado por um *foundation model*. Para cada um dos modelos terá o comportamento do máximo *drawdown*, bem como a evolução do montante acumulado ao longo dos dias. Os demais gráficos dos resultados dos outros modelos foram incluídos no Apêndice A, a fim de evitar redundâncias no corpo principal do texto.

4.2.2.1 Abev3

Tabela 15 – Comparação resultados da simulação de *day trading* - ABEV3

Modelo	Modo	Incerteza	Capital final	Taxa de sucesso	Traded days	MDD	Final score
RF [9]	-	-	R\$ 541.123	60.26%	40	6.46%	0.81
RF [9]	-	30%	R\$ 560.897	66.0%	22	2.73%	0.86
TimesFM	Zero shot	-	R\$ 445.540	46.58%	40	15.7%	0.642
Chronos	Zero shot	-	R\$ 430.231	41.67%	40	19.9%	0.60
Chronos	Fine tuning	-	R\$ 546.182	58.70%	40	9.20%	0.813
Chronos	Fine tuning	25%	R\$ 514.578	63.64%	5	1.56%	0.805

Fonte: O autor (2025).

Figura 18 – Resultados simulação *day trading* Chronos (Fine tuned) x Random Forest (30%) - ABEV3

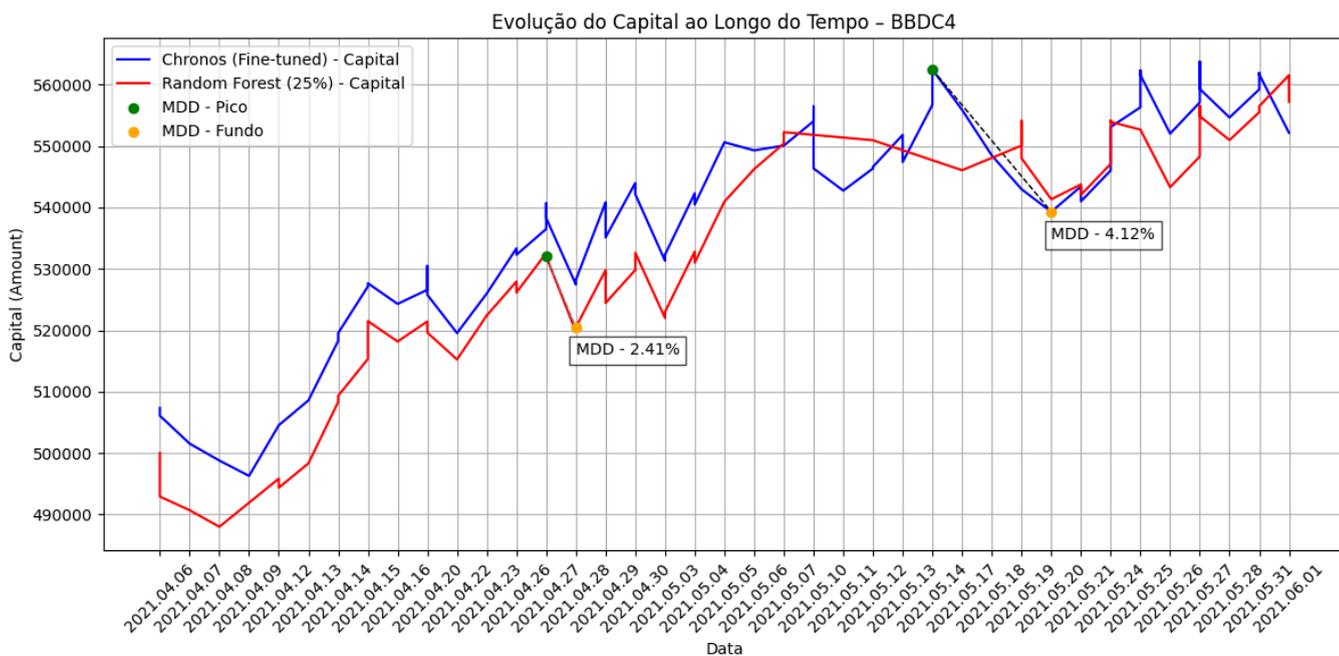
Fonte: O autor (2025).

4.2.2.2 Bbdc4

Tabela 16 – Comparação resultados da simulação de *day trading* - BBDC4

Modelo	Modo	Incerteza	Capital final	Taxa de sucesso	Traded days	MDD	Final score
RF [9]	-	-	R\$ 552.403	53.73%	40	4.76%	0.81
RF [9]	-	25%	R\$ 557.222	55.17%	34	2.41%	0.82
TimesFM	Zero shot	-	R\$ 467.890	45.24%	40	7.12%	0.682
Chronos	Zero shot	-	R\$ 454.906	48.1%	40	14,0%	0.662
Chronos	Fine tuning	-	R\$ 552.178	57.75%	40	4.12%	0.827
Chronos	Fine tuning	75%	R\$ 529.672	54.55%	31	2.67%	0.793

Fonte: O autor (2025).

Figura 19 – Resultados simulação *day trading* Chronos (Fine tuned) x Random Forest (25%)- BBDC4

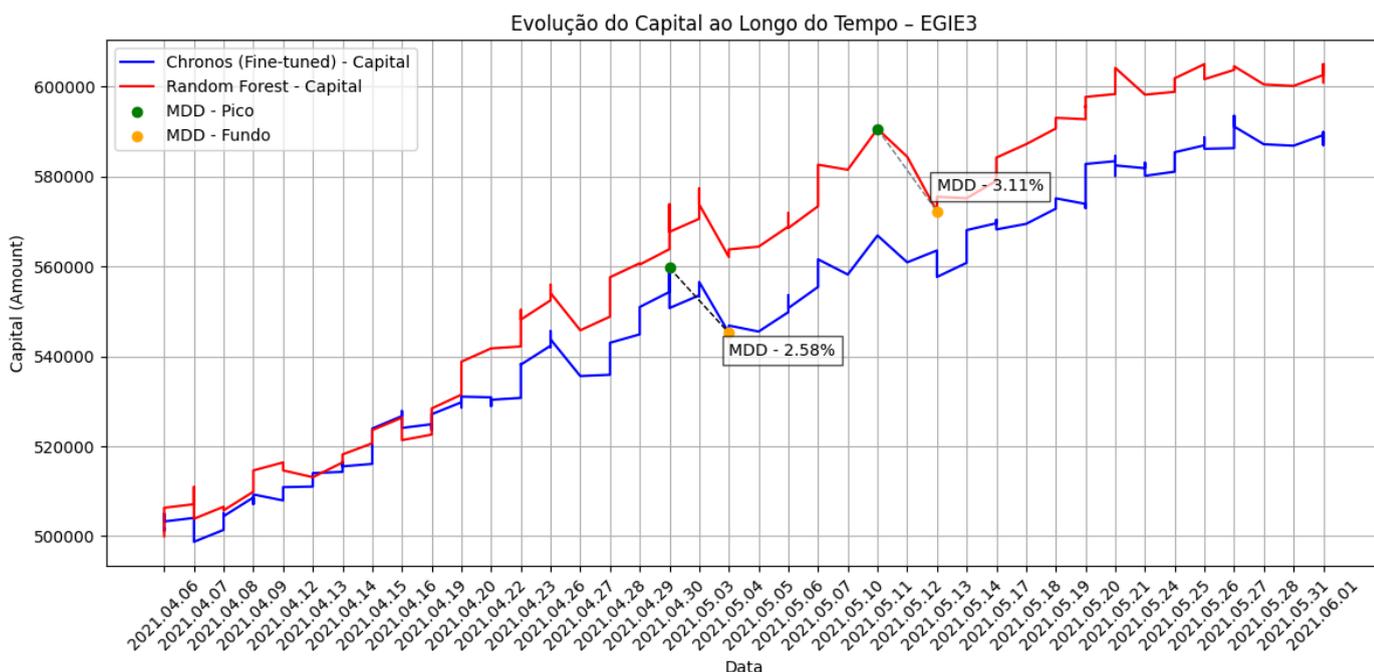
Fonte: O autor (2025).

4.2.2.3 Egie3

Tabela 17 – Comparação resultados da simulação de *day trading* - EGIE3

Modelo	Modo	Incerteza	Capital final	Taxa de sucesso	Traded days	MDD	Final score
RF [9]	-	-	R\$ 600.914	78.05%	40	3.11%	0.95
RF [9]	-	20%	R\$ 561.544	76.14%	25	1.84%	0.90
<i>TimesFM</i>	<i>Zero shot</i>	-	R\$ 508.315	59.26%	40	5.91%	0.775
<i>Chronos</i>	<i>Zero shot</i>	-	R\$ 528.656	55.17%	40	4.18%	0.791
<i>Chronos</i>	<i>Fine tuning</i>	-	R\$ 588.906	63.27%	40	2.58%	0.891
<i>Chronos</i>	<i>Fine tuning</i>	35%	R\$ 530.977	67.12%	10	1.23%	0.836

Fonte: O autor (2025).

Figura 20 – Resultados simulação *day trading Chronos (Fine tuned) x Random Forest (Sem incerteza)* - EGIE3

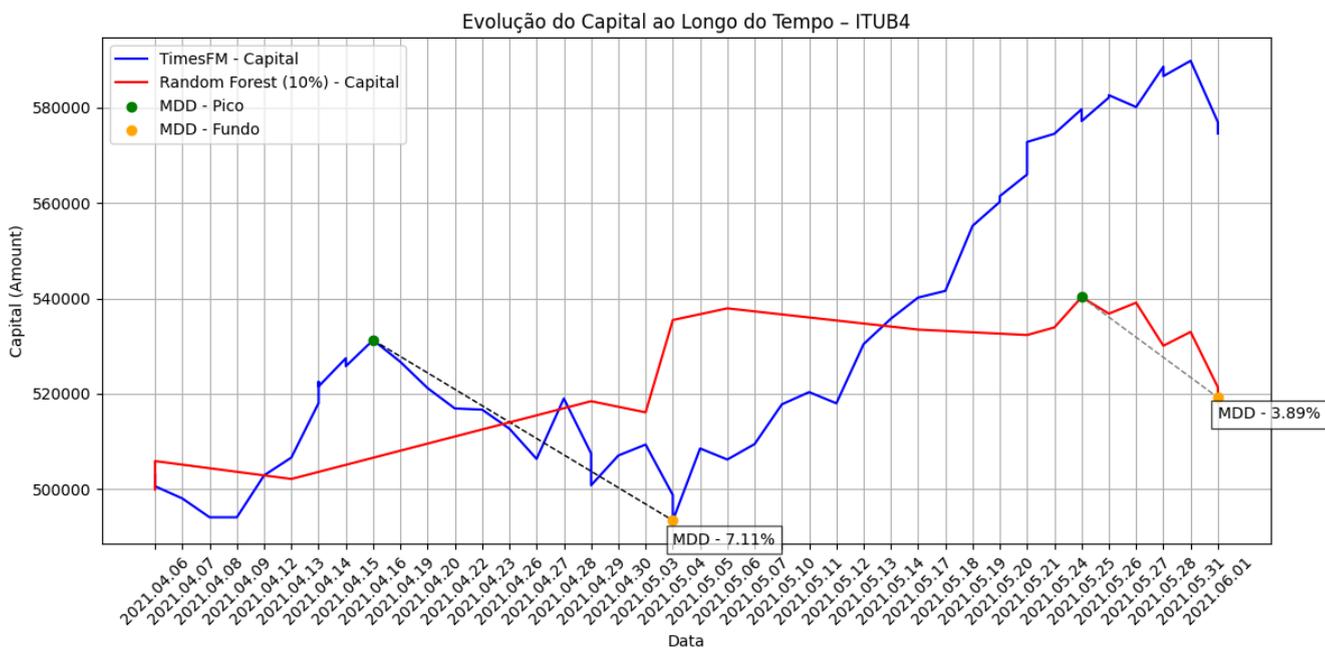
Fonte: O autor (2025).

4.2.2.4 Itub4

Tabela 18 – Comparação resultados da simulação de *day trading* - ITUB4

Modelo	Modo	Incerteza	Capital final	Taxa de sucesso	Traded days	MDD	Final score
RF [9]	-	-	R\$ 493.066	51.79%	40	7.47%	0.73
RF [9]	-	10%	R\$ 519.238	50%	15	3.89%	0.76
<i>TimesFM</i>	<i>Zero shot</i>	-	R\$ 574.522	56.6%	40	7.11%	0.845
<i>Chronos</i>	<i>Zero shot</i>	-	R\$ 520.816	53.57%	40	5.45%	0.774
<i>Chronos</i>	<i>Fine tuning</i>	-	R\$ 494.936	46.43%	40	7.11%	0.71
<i>Chronos</i>	<i>Fine tuning</i>	35%	R\$ 515.721	63.64%	6	2.37%	0.80

Fonte: O autor (2025).

Figura 21 – Resultados simulação *day trading TimesFM* x *Random Forest* (10%) - ITUB4

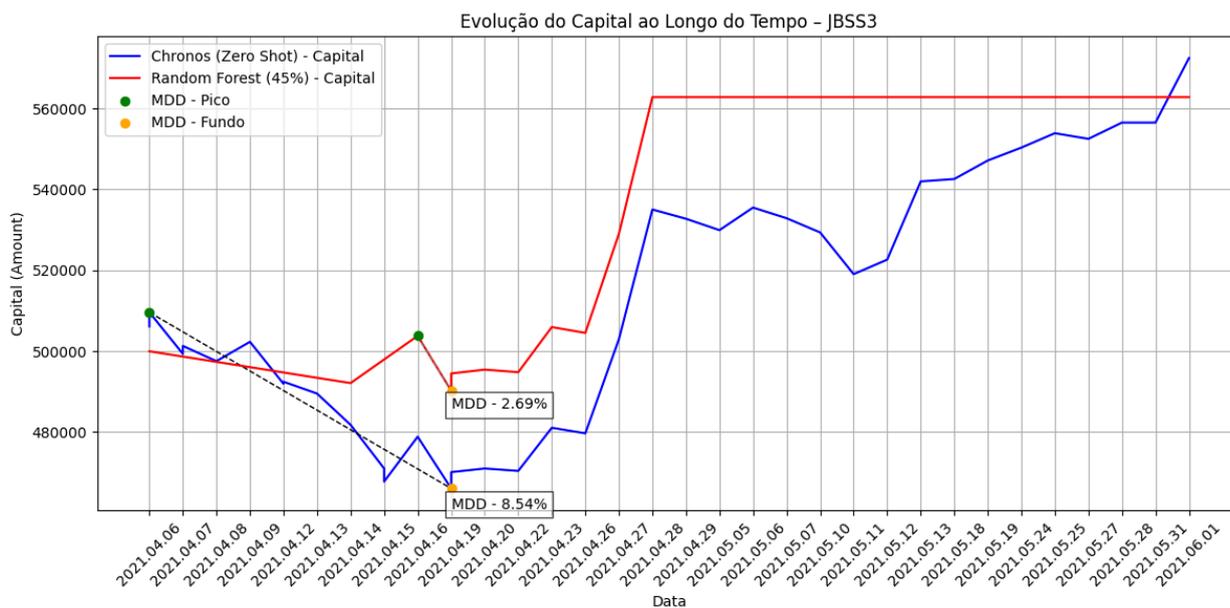
Fonte: O autor (2025).

4.2.2.5 Jbss3

Tabela 19 – Comparação resultados da simulação de *day trading* - JBSS3

Modelo	Modo	Incerteza	Capital final	Taxa de sucesso	Traded days	MDD	Final score
RF [9]	-	-	R\$ 500.445	49.02%	40	9.12%	0.73
RF [9]	-	45%	R\$ 562.809	60%	9	2.69%	0.85
TimesFM	Zero shot	-	R\$ 510.607	46.97%	40	10.4%	0.732
Chronos	Zero shot	-	R\$ 572.475	54.05%	40	8.54%	0.832
Chronos	Fine tuning	-	R\$ 503.939	52.54%	40	9.11%	0.744
Chronos	Fine tuning	45%	R\$ 544.617	59.38%	19	7.27%	0.817

Fonte: O autor (2025).

Figura 22 – Resultados simulação *day trading* Chronos (Zero Shot) Random Forest (45%) - JBSS3

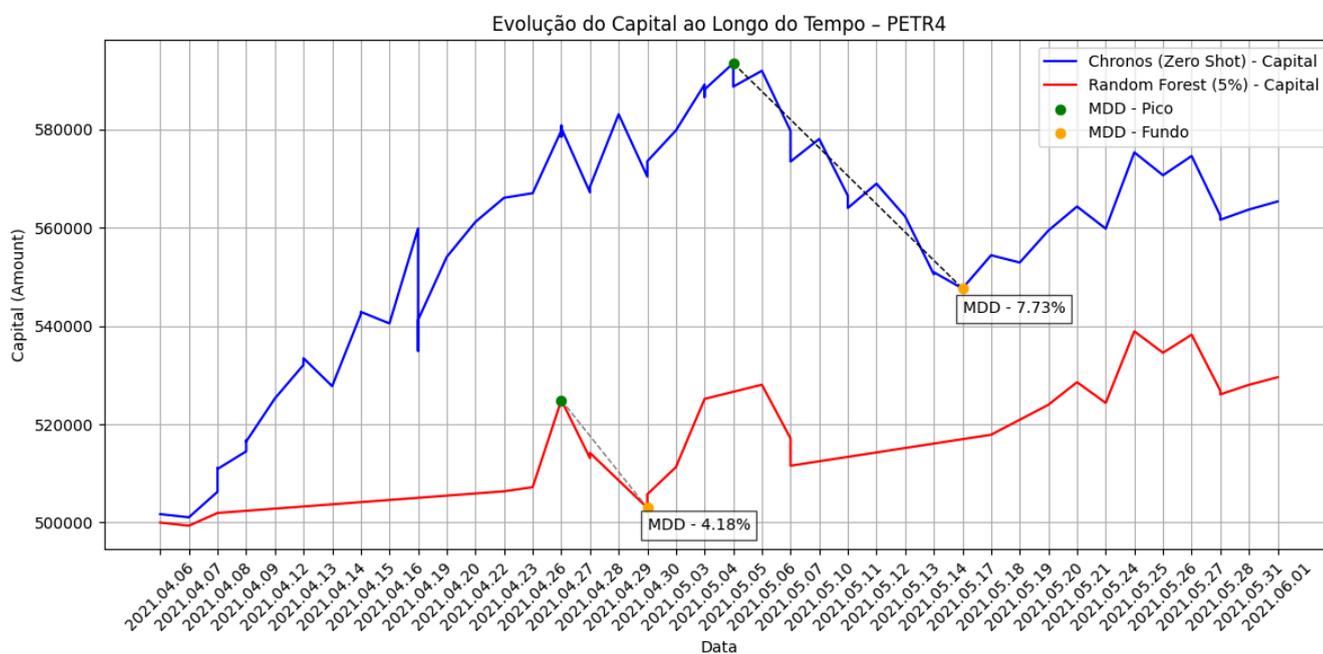
Fonte: O autor (2025).

4.2.2.6 Petr4

Tabela 20 – Comparação resultados da simulação de *day trading* - PETR4

Modelo	Modo	Incerteza	Capital final	Taxa de sucesso	Traded days	MDD	Final score
RF [9]	-	-	R\$ 506.076	57.3%	40	9.32%	0.76
RF [9]	-	5%	R\$ 542.533	72.73%	19	4.18%	0.86
TimesFM	Zero shot	-	R\$ 551.999	58.82%	40	9.44%	0.819
Chronos	Zero shot	-	R\$ 565.370	60.87	40	7.73%	0.845
Chronos	Fine tuning	-	R\$ 543.560	61.70%	40	5.87%	0.825
Chronos	Fine tuning	55%	R\$ 521.297	62.86%	15	2.89%	0.808

Fonte: O autor (2025).

Figura 23 – Resultados simulação *day trading* Chronos (Zero Shot) x Random Forest (5%) - PETR4

Fonte: O autor (2025).

Diante dos resultados obtidos, observa-se que os modelos de base apresentaram desempenho inferior ao modelo *Random Forest*, que se destacou em 4 das 6 ações analisadas. Além disso, a aplicação da incerteza no modelo *Chronos* após o *fine tuning* não demonstrou vantagens significativas, como foi o caso do *Random Forest*. Em nenhum dos casos o *Chronos* com incerteza superou os demais modelos, e, em diversas situações, apresentou um capital final inferior até mesmo ao dos modelos de base sem *fine tuning*.

Esse resultado pode ser atribuído ao fato de que, mesmo após o *fine tuning*, os intervalos de incerteza diária permaneceram elevados. Isso reduziu significativamente a quantidade de dias em que o sistema pôde operar com confiança, limitando as oportunidades de *trade* e impactando negativamente os resultados finais.

5 CONCLUSÃO

Este trabalho teve como objetivo avaliar a aplicabilidade de modelos de base na previsão de preços de ações no mercado financeiro brasileiro, utilizando estratégias de *day trading* como base para a comparação de desempenho. O estudo também considerou a influência da incorporação da incerteza na tomada de decisão e a importância do uso de covariáveis para enriquecer o contexto preditivo. Os resultados obtidos foram comparados com os de um modelo *Random Forest*, previamente desenvolvido por Sobral [9].

Os experimentos demonstraram que os *foundation models*, quando utilizados em modo *zero-shot*, apresentaram desempenho inferior ao modelo *Random Forest* em praticamente todos os cenários analisados. Isso se deve, principalmente, à limitação desses modelos em incorporar covariáveis no modo *zero-shot*, tornando suas previsões excessivamente genéricas e sensíveis à incerteza acumulada.

Por outro lado, quando o modelo *Chronos* foi submetido ao processo de *fine-tuning* com os dados do contexto financeiro analisado e com a adição de covariáveis, como preço de abertura, máximas e mínimas dos dias anteriores, *EMA* e Bandas de *Bollinger*, seu desempenho foi significativamente aprimorado. Em diversos casos, como em BBDC4, EGIE3, JBSS3 e PETR4, o *Chronos fine-tuned* sem incerteza obteve *scores* finais muito próximos ou até superiores aos do *Random Forest*, demonstrando a viabilidade dessa abordagem mais recente no contexto do mercado financeiro.

A análise de incerteza aplicada ao *Chronos* não se mostrou tão relevante quanto a feita sob o *Random Forest*: conforme o limite de incerteza era ajustado para valores mais conservadores, o sistema reduzia muito o número de operações, os *drawdowns* eram significativamente menores, mas o capital final acumulado ficou muito abaixo dos outros modelos.

Assim, conclui-se que, embora os *foundation models* ainda não superem, de forma consistente, modelos tradicionais bem ajustados como o *Random Forest*, o uso de *fine-tuning* com covariáveis pode torná-los competitivos e promissores para aplicações futuras em mercados financeiros.

6 LIMITAÇÕES E TRABALHOS FUTUROS

Apesar dos resultados promissores obtidos com o uso de *foundation models* aplicados à previsão de preços no mercado financeiro, este trabalho apresenta algumas limitações que abrem espaço para aprimoramentos e investigações futuras.

Em primeiro lugar, a aplicação foi restrita a modelos univariados, limitando a riqueza contextual disponível para a previsão. Assim, uma linha de pesquisa futura relevante seria a exploração de modelos de base multivariados, capazes de lidar nativamente com múltiplas variáveis simultaneamente. Isso permitiria incorporar informações adicionais como indicadores técnicos, variáveis macroeconômicas, sentimento de mercado e volume de negociação.

Além disso, a análise foi feita apenas sobre seis ações da B3 em um período fixo. Estudos futuros podem expandir a amostra para incluir uma maior variedade de ativos, setores e janelas temporais, o que contribuiria para uma avaliação mais robusta da generalização dos modelos.

Também pode ser feita uma análise diferente dos níveis de quantile, utilizando outros valores (que não os de 90% e 10%) para se estabelecer o intervalo de incerteza, e talvez assim, contribuir para a diminuição do *drawdown* mas sem impactar negativamente o ganho de capital e a quantidade de dias de operações.

Também se destaca como oportunidade futura a realização de *fine-tuning* no modelo *TimesFM*, com o objetivo de verificar se essa abordagem pode melhorar sua performance preditiva

Por fim, seria interessante aprofundar o estudo sobre o uso da incerteza na tomada de decisão, testando diferentes estratégias de gestão de risco, como limites dinâmicos de operação, integração com indicadores de volatilidade, ou a aplicação em contextos de swing trading ou position trading [20], que envolvem janelas temporais maiores.

REFERÊNCIAS

- [1] AMAZON SCIENCE. *Chronos* – Learning the language of time series. Disponível em: <https://www.amazon.science/code-and-datasets/chronos-learning-the-language-of-time-series>. Acesso em: 26 jun. 2025.
- [2] BOMMASANI, R. et al. On the opportunities and risks of foundation models. arXiv preprint arXiv:2108.07258, 2021.
- [3] BREIMAN, L. *Random forests*. Machine learning, v. 45, n. 1, p. 5–32, 2001.
- [4] FAMA, E. F. Efficient Capital Markets: A Review of Theory and Empirical Work. The Journal of Finance, v. 25, n. 2, p. 383–417, 1970.
- [5] JORDAN, M. I.; MITCHELL, T. M. Machine learning: Trends, perspectives, and prospects. Science, v. 349, n. 6245, p. 255–260, 2015.
- [6] DAS, Abhimanyu; KONG, Weihao; SEN, Rajat; ZHOU, Yichen. A decoder-only foundation model for time-series forecasting. arXiv, 14 out. 2023. Disponível em: <https://arxiv.org/abs/2310.10688>. Acesso em: 01 jul. 2025.
- [7] MARTINEZ, L. C.; HORA, D. N. da; PALOTTI, J. R. de M.; MEIRA, W.; PAPPA, G. L. From an artificial neural network to a stock market day-trading system: A case study on the bmf bovespa. In: 2009 International Joint Conference on Neural Networks. [S.l.: s.n.], 2009. p. 2006–2013.
- [8] AMAZON WEB SERVICES – AWS. What are foundation models? Disponível em: <https://aws.amazon.com/what-is/foundation-models/>. Acesso em: 26 jun. 2025.
- [9] SOBRAL, João Felipe Moraes Vasconcelos. Modelagem de Incerteza com *Random Forest* para Estratégias de Investimento em Ações — Universidade Federal de Pernambuco (UFPE), Centro de Informática, 2025.
- [10] FILHO, A. C. d. A. Avaliação do método de *random forest* para indicar o melhor momento de compra e venda de ações no mercado financeiro. Trabalho de Conclusão de Curso — Universidade Federal de Pernambuco (UFPE), Centro de Informática, 2021.
- [11] JUNIOR, L. A. d. A. Sistema automático para operações day trade baseado em previsão de valores máximos e mínimos com *random forest*. Trabalho de Conclusão de Curso — Universidade Federal de Pernambuco (UFPE), Centro de Informática, 2022.
- [12] MARTINEZ, L. C.; HORA, D. N. da; PALOTTI, J. R. de M.; MEIRA, W.; PAPPA, G. L. From an artificial neural network to a stock market day-trading system: A case study on the bmf bovespa. In: 2009 International Joint Conference on Neural Networks. [S.l.: s.n.], 2009. p. 2006–2013.

- [13] FREITAS, Alex A.; SILVA, André S. da; FUKS, Hugo. *Aplicação de técnicas de mineração de dados para previsão do mercado de ações*. Revista de Administração da UEG, v. 1, n. 1, p. 32–42, 2009.
- [14] INVESTOPEDIA. Exponential Moving Average (EMA). Disponível em: <https://www.investopedia.com/terms/e/ema.asp>. Acesso em: 28 jun. 2025.
- [15] INFOMONEY. Bandas de Bollinger: o que são, estratégias e como utilizar na prática. Disponível em: <https://www.infomoney.com.br/guias/bandas-bollinger/>. Acesso em: 28 jun. 2025.
- [16] CRAIG, Lev. *What is fine-tuning in machine learning and AI?* Disponível em: <https://www.techtarget.com/searchenterpriseai/definition/fine-tuning>. Acesso em: 2 jul. 2025.
- [17] SHCHUR, Oleksandr; TURKMEN, Caner; ERICKSON, Nick; et al. *AutoGluon–TimeSeries: AutoML for probabilistic time series forecasting*. arXiv, 10 ago. 2023. Disponível em: <https://arxiv.org/abs/2308.05566>. Acesso em: 02 jul. 2025.
- [18] AUTOML.GLUON. Forecasting with *Chronos* (AutoGluon-TimeSeries). Disponível em: <https://auto.gluon.ai/stable/tutorials/timeseries/forecasting-chronos.html>. Acesso em: 02 jul. 2025.
- [19] INVESTOPEDIA. *Stop-Loss Order*. Disponível em: <https://www.investopedia.com/terms/s/stop-lossorder.asp>. Acesso em: 07 jul. 2025.
- [20] NELOGICA. Day, swing e position trading: entenda as diferenças. Disponível em: <https://www.nelogica.com.br/conhecimento/artigos/trading/day-swing-position>. Acesso em: 09 jul. 2025.
- [21] INFO MONEY. Lucro da Yduqs cai 74%, Via lucra 1.285%, mais BRF, JBS, Suzano, Eletrobras e mais balanços: confira outros destaques. *InfoMoney*, São Paulo, 13 maio 2021. Disponível em: <https://www.infomoney.com.br/mercados/lucro-da-yduqs-cai-74-via-lucra-1-285-mais-brf-jbs-suzano-eletobras-e-mais-balancos-confira-outros-destaques/>. Acesso em: 12 jul. 2025.
- [22] MONEY TIMES. JBS pagará R\$ 2,5 bilhões em dividendos. *Money Times*, São Paulo, 28 abr. 2021. Disponível em: <https://www.moneytimes.com.br/jbs-pagara-r-25-bilhoes-em-dividendos/>. Acesso em: 12 jul. 2025.
- [23] CORPORATE FINANCE INSTITUTE (CFI). Maximum Drawdown – Overview, Investment Risk, Portfolios. Disponível em: https://corporatefinanceinstitute.com/resources/career-map/sell-side/capital-markets/maximum-drawdown/?utm_source=chatgpt.com. Acesso em: 23 jul. 2025.

APÊNDICE A – LINKS PARA COMPLEMENTOS DIGITAIS

- Todos os gráficos gerados pelas previsões dos modelos utilizados neste trabalho estão disponíveis no seguinte endereço eletrônico:
<https://github.com/RodrigoMesel/DayTradeSystem/blob/main/DayTradeSystem/Rodrigo/Resultados/Resultados%20TCC%20-%20Predi%C3%A7%C3%A3o%20de%20m%C3%A1xima%20e%20m%C3%ADnima.pdf>
- Os resultados da simulação de estratégias de *Day Trading* podem ser acessados em:
<https://github.com/RodrigoMesel/DayTradeSystem/blob/main/DayTradeSystem/Rodrigo/Resultados/Resultados%20TCC%20-%20Simula%C3%A7%C3%A3o%20Day%20trading.pdf>
- O código-fonte completo que implementa os modelos e simulações está disponível no repositório:
<https://github.com/RodrigoMesel/DayTradeSystem/tree/main/DayTradeSystem/Rodrigo>