

UNIVERSIDADE FEDERAL DE MINAS GERAIS
Instituto de Ciências Exatas
Programa de Pós-Graduação em Ciência da Computação

Johnathas Araújo de Carvalho

**Sistema de gestão de risco em operações automatizadas na bolsa de valores
baseado em aprendizado profundo**

Belo Horizonte
2022

Johnathas Araújo de Carvalho

**Sistema de gestão de risco em operações automatizadas na bolsa de valores
baseado em aprendizado profundo**

Versão Final

Dissertação apresentada ao Programa de Pós-Graduação em
Ciência da Computação da Universidade Federal de Minas
Gerais, como requisito parcial à obtenção do título de Mestre
em Ciência da Computação.

Orientador: Adriano César Machado Pereira

Belo Horizonte
2022

2022, Johnathas Araújo de Carvalho.
Todos os direitos reservados

Carvalho, Johnathas Araújo de.

C331s Sistema de gestão de risco em operações automatizadas na bolsa de valores baseado em aprendizado profundo [manuscrito] / Johnathas Araújo de Carvalho. — 2022. 157 f. il.

Orientador: Adriano César Machado Pereira
Dissertação (mestrado) - Universidade Federal de Minas Gerais, Instituto de Ciências Exatas, Departamento de Ciência da Computação.
Referências 111-113.

1. Ciência da Computação – Teses. 2. Aprendizado do computador – Teses. 3. Gestão de riscos – Teses. 4. Algoritmos de computador – Teses. I. Pereira, Adriano César Machado. II. Universidade Federal de Minas Gerais, Instituto de Ciências Exatas, Departamento de Ciência da Computação. III. Título.

CDU 519.6*82(043)

Ficha catalográfica elaborada pela bibliotecária Irenquer Vismeg Lucas Cruz, CRB 6/819 - Universidade Federal de Minas Gerais - ICEX



UNIVERSIDADE FEDERAL DE MINAS GERAIS
INSTITUTO DE CIÊNCIAS EXATAS
DEPARTAMENTO DE CIÊNCIA DA COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

FOLHA DE APROVAÇÃO

SISTEMA DE GESTÃO DE RISCO EM OPERAÇÕES AUTOMATIZADAS NA BOLSA DE VALORES BASEADO EM APRENDIZADO PROFUNDO

JOHNATHAS ARAÚJO DE CARVALHO

Dissertação defendida e aprovada pela banca examinadora constituída pelos Senhores:

Prof. Adriano César Machado Pereira - Orientador
Departamento de Ciência da Computação - UFMG

Prof. Flávio Luis Cardeal Pádua
Departamento de Computação - CEFET-MG

Prof. Heitor Soares Ramos Filho
Departamento de Ciência da Computação - UFMG

Belo Horizonte, 17 de agosto de 2022.



Documento assinado eletronicamente por **Flávio Luis Cardeal Pádua, Usuário Externo**, em 27/10/2022, às 16:15, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Adriano Cesar Machado Pereira, Professor do Magistério Superior**, em 21/12/2022, às 14:43, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Heitor Soares Ramos Filho, Professor do Magistério Superior**, em 21/12/2022, às 15:03, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1864456** e o código CRC **9EE3F463**.

Dedico este trabalho à minha família, o meu bem maior, aos meus filhos (Augusto, André e Maria) e a minha esposa Andréia.

“In theory, there is no difference between theory and practice. But in practice, there is.”
(Benjamin Brewster)

Resumo

Diversos trabalhos têm utilizado algoritmos de aprendizado de máquina e *deep learning* para realizar a predição de séries temporais financeiras ou prever a direção de movimento de preço de ativos, e demonstrado melhor desempenho em relação aos tradicionais métodos econométricos. Entretanto, ainda não há trabalhos que realizem um estudo sistemático do resultado histórico das predições a fim de estabelecer um sistema de gestão de risco (SGR) para operações automatizadas (*algotrading*).

Este trabalho aplicou algoritmos de aprendizado profundo, especificamente as redes LSTM e Bi-LSTM, para realizar a predição de limites diários de negociação de um ativo (valores máximo e mínimo do ativo). Um estudo estatístico e sistemático das predições do modelo nos dados de treino permitiu estimar a probabilidade de acerto, relação de risco/ganho, bem como mensurar o grau de exposição adequado. As predições de limites foram utilizadas para filtrar as sugestões de operações de sete estratégias automatizadas baseadas em cruzamento de médias e osciladores (RSI e MACD).

Simulações foram realizadas em 5 ativos mais negociados da B3 entre 2008 e 2019 (ABEV3, B3SA3, ITUB4, PETR4 e USIM5) e em 7 estratégias automatizadas. Os resultados indicaram que, apesar do grau de incerteza das predições dos modelos, a utilização do SGR proposto apresentou melhor desempenho em relação ao retorno líquido financeiro das estratégias em 64% das situações e ganho médio no retorno líquido de 0,31%. As estratégias que utilizaram SGR e que apresentaram melhor desempenho tiveram um retorno sobre o capital alocado superior ao *baseline* estabelecido de *buy-and-hold*.

Palavras-chave: gestão de risco, *algotrading*, aprendizado profundo.

Abstract

Machine learning and deep learning algorithms are being used by several studies to predict future values in financial series or the direction of assets price movements, and proved to outperform the traditional econometric models. Nevertheless, there are not yet working papers that conduct systematical analysis of historical predictions in order to establish a risk management system (RMS) for automated trades (algotrading).

This work employ deep learning algorithms, specifically the LSTM and Bi-LSTM networks, to predict daily trading ranges of assets (high and low prices). A statistical and systematical analysis of the predictions allow to estimate the hit probability, risk/gain ratio, as well to measure more adequate exposure sizes. The range predictions were applied to filter suggested operations of seven automated trading strategies based on moving average and oscillatores (RSI and MACD).

Backtestings were performed upon 5 most negotiated assets in B3 between 2008 and 2019 (ABEV3, B3SA3, ITUB4, PETR4 and USIM5). The results pointed that, despite of the predictions uncertainty of the models, the appliance of RMS outperformed the strategies in terms of net return in 64% of the cases and demonstrated average gain of 0,31% in the net return of the strategies. Those strategies that made use of risk management system and had the best performance for each tested asset also had a net return over allocated capital greater than the baseline defined as buy-and-hold strategy.

Keywords: risk management, algotrading, deep learning.

Lista de Figuras

3.1	Exemplo da aplicação de SGR sobre uma estratégia arbitrária de <i>algotrading</i>	32
3.2	Diagrama esquemático da arquitetura de Redes Neurais Recorrentes	33
3.3	Diagrama esquemático da estrutura de uma célula LSTM	34
3.4	Diagrama esquemático da estrutura de uma rede BiLSTM	36
3.5	Diagrama esquemático do mecanismo de atenção aplicado a rede BiLSTM	37
3.6	Gráfico exemplificativo da utilização de médias móveis simples e exponencial	39
3.7	Exemplo do indicador RSI	40
3.8	Exemplo do indicador MACD	41
3.9	Exemplo do indicador de Canal de Keltner	42
3.10	Exemplo do indicador OBV	43
3.11	Exemplo do indicador VWAP diário	45
4.1	Etapas metodológicas para desenvolvimento do Sistema de Gestão de Risco	48
4.2	Representação de dados por meio de <i>Candlestick</i>	49
4.3	Exemplo de gráfico de <i>candles</i>	50
4.4	Algoritmo do Sistema de Gestão de Risco (SGR)	57
4.5	Estratégia <i>Buy low/Sell high</i>	60
4.6	Estratégia <i>Act on opening</i>	61
4.7	Estratégia de negociação baseada no cruzamento de média (<i>crossover</i>)	62
4.8	Estratégia de negociação baseada no cruzamento de 2 médias móveis (<i>double crossover</i>)	63
4.9	Estratégia de negociação baseada no cruzamento de três médias móveis (<i>triple crossover</i>) com liquidação de posição	65
4.10	Estratégia de negociação baseada no cruzamento de três médias móveis (<i>triple crossover</i>) com reversão de posição	65
4.11	Estratégia de negociação baseada no indicado RSI	67
4.12	Estratégia de negociação baseada no indicador MACD com liquidação de posição	68
4.13	Estratégia de negociação baseada no indicador MACD com reversão de posição	69
5.1	Probabilidade condicional de tendência de baixa	74
5.2	Probabilidade condicional de tendência de alta	75
5.3	Distribuição dos erros de predição do modelo selecionado para o ativo ABEV3	79
5.4	Distribuição dos erros de predição do modelo selecionado para o ativo B3SA3	80
5.5	Distribuição dos erros de predição do modelo selecionado para o ativo ITUB4	80

Lista de Figuras

5.6	Distribuição dos erros de predição do modelo selecionado para o ativo PETR4	81
5.7	Distribuição dos erros de predição do modelo selecionado para o ativo USIM5	81
5.8	Melhor caso de ABEV3 - <i>Trades</i> da estratégia MACD (Posicionado) sem uso do SGR	88
5.9	Melhor caso de ABEV3 - <i>Trades</i> da estratégia MACD (Posicionado) utilizando SGR	88
5.10	Pior caso de ABEV3 - <i>Trades</i> da estratégia RSI sem uso do SGR	89
5.11	Pior caso de ABEV3 - <i>Trades</i> da estratégia RSI utilizando SGR	90
5.12	Melhor caso de B3SA3 - <i>Trades</i> da estratégia RSI sem uso do SGR	92
5.13	Melhor caso de B3SA3 - <i>Trades</i> da estratégia RSI utilizando SGR	92
5.14	Pior caso de B3SA3 - <i>Trades</i> da estratégia Cruzamento de média sem uso do SGR	94
5.15	Pior caso de B3SA3 - <i>Trades</i> da estratégia Cruzamento de média utilizando SGR	94
5.16	Melhor caso de ITUB4 - <i>Trades</i> da estratégia RSI sem uso do SGR	96
5.17	Melhor caso de ITUB4 - <i>Trades</i> da estratégia RSI utilizando SGR	96
5.18	Pior caso de ITUB4 - <i>Trades</i> da estratégia <i>Act on opening</i> sem uso do SGR	97
5.19	Pior caso de ITUB4 - <i>Trades</i> da estratégia <i>Act on opening</i> utilizando SGR	98
5.20	Melhor caso de PETR4 - <i>Trades</i> da estratégia MACD (Posicionado) sem uso do SGR	100
5.21	Melhor caso de PETR4 - <i>Trades</i> da estratégia MACD (Posicionado) utilizando SGR	100
5.22	Pior caso de PETR4 - <i>Trades</i> da estratégia <i>Act on opening</i> sem uso do SGR	101
5.23	Pior caso de PETR4 - <i>Trades</i> da estratégia <i>Act on opening</i> utilizando SGR	101
5.24	Melhor caso de USIM5 - <i>Trades</i> da estratégia <i>Buy low/Sell high</i> sem uso do SGR	103
5.25	Melhor caso de USIM5 - <i>Trades</i> da estratégia <i>Buy low/Sell high</i> utilizando SGR	103
5.26	Pior caso de USIM5 - <i>Trades</i> da estratégia MACD (Posicionado) sem uso do SGR	105
5.27	Pior caso de USIM5 - <i>Trades</i> da estratégia MACD (Posicionado) utilizando SGR	105
A.1	ABEV3 - Distribuição de RMSE dos modelos treinados por cada conjunto de dados de entrada	115
A.2	B3SA3 - Distribuição de RMSE dos modelos treinados por cada conjunto de dados de entrada	116
A.3	ITUB4 - Distribuição de RMSE dos modelos treinados por cada conjunto de dados de entrada	117
A.4	PETR4 - Distribuição de RMSE dos modelos treinados por cada conjunto de dados de entrada	118

A.5	USIM5 - Distribuição de RMSE dos modelos treinados por cada conjunto de dados de entrada	119
A.6	ABEV3 - Distribuição de RMSE dos modelos LSTM/BiLSTM treinados por cada conjunto de dados de entrada	121
A.7	B3SA3 - Distribuição de RMSE dos modelos LSTM/BiLSTM treinados por cada conjunto de dados de entrada	122
A.8	ITUB4 - Distribuição de RMSE dos modelos LSTM/BiLSTM treinados por cada conjunto de dados de entrada	123
A.9	PETR4 - Distribuição de RMSE dos modelos LSTM/BiLSTM treinados por cada conjunto de dados de entrada	124
A.10	USIM5 - Distribuição de RMSE dos modelos LSTM/BiLSTM treinados por cada conjunto de dados de entrada	125
A.11	ABEV3 - Distribuição de RMSE dos modelos com/sem mecanismo de atenção treinados por cada conjunto de dados de entrada	127
A.12	B3SA3 - Distribuição de RMSE dos modelos com/sem mecanismo de atenção treinados por cada conjunto de dados de entrada	128
A.13	ITUB4 - Distribuição de RMSE dos modelos com/sem mecanismo de atenção treinados por cada conjunto de dados de entrada	129
A.14	PETR4 - Distribuição de RMSE dos modelos com/sem mecanismo de atenção treinados por cada conjunto de dados de entrada	130
A.15	USIM5 - Distribuição de RMSE dos modelos com/sem mecanismo de atenção treinados por cada conjunto de dados de entrada	131
A.16	ABEV3 - Gráfico de boxplot do valor de RMSE nos dados de validação agrupado por tamanho da janela do modelo	134
A.17	B3SA3 - Gráfico de boxplot do valor de RMSE nos dados de validação agrupado por tamanho da janela do modelo	134
A.18	ITUB4 - Gráfico de boxplot do valor de RMSE nos dados de validação agrupado por tamanho da janela do modelo	135
A.19	PETR4 - Gráfico de boxplot do valor de RMSE nos dados de validação agrupado por tamanho da janela do modelo	135
A.20	USIM5 - Gráfico de boxplot do valor de RMSE nos dados de validação agrupado por tamanho de janela do modelo	136
B.1	ABEV3 - Gráfico boxplot das variáveis de log-retorno	137
B.2	B3SA3 - Gráfico boxplot das variáveis de log-retorno	138
B.3	ITUB4 - Gráfico boxplot das variáveis de log-retorno	138
B.4	PETR4 - Gráfico boxplot das variáveis de log-retorno	139
B.5	USIM5 - Gráfico boxplot das variáveis de log-retorno	139
B.6	ABEV3 - Mapa de calor das váriaveis de log-retorno	140

B.7	B3SA3 - Mapa de calor das variáveis de log-retorno	141
B.8	ITUB4 - Mapa de calor das variáveis de log-retorno	142
B.9	PETR4 - Mapa de calor das variáveis de log-retorno	143
B.10	USIM5 - Mapa de calor das variáveis de log-retorno	144
B.11	ABEV3 - Gráfico de distribuição e dispersão das variáveis de log-retorno	145
B.12	B3SA3 - Gráfico de distribuição e dispersão das variáveis de log-retorno	146
B.13	ITUB4 - Gráfico de distribuição e dispersão das variáveis de log-retorno	147
B.14	PETR4 - Gráfico de distribuição e dispersão das variáveis de log-retorno	148
B.15	USIM5 - Gráfico de distribuição e dispersão das variáveis de log-retorno	149
B.16	ABEV3 - Distribuição dos retornos percentuais dos valores máximos e mínimos em relação ao preço de abertura do dia	150
B.17	B3SA3 - Distribuição dos retornos percentuais dos valores máximos e mínimos em relação ao preço de abertura do dia	151
B.18	ITUB4 - Distribuição dos retornos percentuais dos valores máximos e mínimos em relação ao preço de abertura do dia	151
B.19	PETR4 - Distribuição dos retornos percentuais dos valores máximos e mínimos em relação ao preço de abertura do dia	152
B.20	USIM5 - Distribuição dos retornos percentuais dos valores máximos e mínimos em relação ao preço de abertura do dia	152
B.21	ABEV3 - Distribuição do retorno percentual do valor máximo em relação ao valor mínimo do dia	153
B.22	B3SA3 - Distribuição do retorno percentual do valor máximo em relação ao valor mínimo do dia	153
B.23	ITUB4 - Distribuição do retorno percentual do valor máximo em relação ao valor mínimo do dia	154
B.24	PETR4 - Distribuição do retorno percentual do valor máximo em relação ao valor mínimo do dia	154
B.25	USIM5 - Distribuição do retorno percentual do valor máximo em relação ao valor mínimo do dia	155
C.1	ABEV3 - Janela temporal de backtesting	156
C.2	B3SA3 - Janela temporal de backtesting	156
C.3	ITUB4 - Janela temporal de backtesting	157
C.4	PETR4 - Janela temporal de backtesting	157
C.5	USIM5 - Janela temporal de backtesting	157

Lista de Tabelas

4.1	Definição das variáveis de entrada para treinamento dos modelos	53
4.2	Parametrização da estrutura dos modelos a serem otimizados	54
4.3	Esforço estimado no processo de otimização da estrutura dos modelos	55
5.1	ABEV3 - Resumo estatístico das variáveis de log-retorno	71
5.2	B3SA3 - Resumo estatístico das variáveis de log-retorno	71
5.3	ITUB4 - Resumo estatístico das variáveis de log-retorno	72
5.4	PETR4 - Resumo estatístico das variáveis de log-retorno	72
5.5	USIM5 - Resumo estatístico das variáveis de log-retorno	72
5.6	Análise de percentil da distribuição de retornos percentuais do valor máximo em relação ao preço de abertura do ativo	73
5.7	Análise de percentil da distribuição de retornos percentuais do valor mínimo em relação ao preço de abertura do ativo	73
5.8	Análise de percentil da distribuição de retornos percentuais do valor máximo em relação ao valor mínimo do ativo em base diária	73
5.9	Média e desvio padrão do valor de RMSE dos modelos de predição selecionados para cada ativo	76
5.10	Predição do valor mínimo - Análise de percentil da distribuição de erros percentuais de predição (eliminando 10% das caudas em cada extremidade)	78
5.11	Predição de valor máximo - Análise de percentil da distribuição de erros percentuais de predição (eliminando 10% das caudas em cada extremidade)	79
5.12	Parâmetros otimizados para cada estratégia e ativo	83
5.13	Tabela de <i>baselines</i> primários para os ativos no <i>backtesting</i>	84
5.14	Tabela de <i>baselines</i> secundários para os ativos no <i>backtesting</i>	85
5.15	ABEV3 - Comparação das estratégias automatizadas com e sem uso do SGR .	87
5.16	ABEV3 - Estratégia com melhor desempenho utilizando SGR - MACD (Posicionado)	87
5.17	ABEV3 - Estratégia com pior desempenho utilizando SGR - RSI	89
5.18	B3SA3 - Comparação das estratégias automatizadas com e sem o uso do SGR	90
5.19	B3SA3 - Estratégia com melhor desempenho utilizando SGR - RSI	91
5.20	B3SA3 - Estratégia com pior desempenho utilizando SGR - Cruzamento de média	93
5.21	ITUB4 - Comparação das estratégias automatizadas com e sem uso do SGR .	96
5.22	ITUB4 - Estratégia com melhor desempenho utilizando SGR - RSI	97

5.23	ITUB4 - Estratégia com pior desempenho utilizando SGR - Cruzamento de média	97
5.24	PETR4 - Comparação das estratégias automatizadas com e sem uso do SGR .	98
5.25	PETR4 - Estratégia com melhor desempenho utilizando SGR - MACD (Posicionado)	99
5.26	PETR4 - Estratégia com pior desempenho utilizando SGR - <i>Act on opening</i> .	99
5.27	USIM5 - Comparação das estratégias automatizadas com e sem uso do SGR .	103
5.28	USIM5 - Estratégia com melhor desempenho utilizando SGR - <i>Buy low/Sell high</i>	104
5.29	USIM5 - Estratégia com pior desempenho utilizando SGR - MACD (Posicionado)	104
5.30	Efetividade da aplicação do SGR nas estratégias automatizadas	107
5.31	Estratégias com melhor desempenho utilizando SGR para cada ativo e retorno sobre capital alocado	107
A.1	ABEV3 - Testes de normalidade <i>Shapiro-Wilk</i> e <i>Mann-Whitney</i> entre pares de amostras RMSE para cada conjunto de dados de entrada	115
A.2	B3SA3 - Testes de normalidade <i>Shapiro-Wilk</i> e <i>Mann-Whitney</i> entre pares de amostras RMSE para cada conjunto de dados de entrada	116
A.3	ITUB4 - Testes de normalidade <i>Shapiro-Wilk</i> e <i>Mann-Whitney</i> entre pares de amostras RMSE para cada conjunto de dados de entrada	117
A.4	PETR4 - Testes de normalidade <i>Shapiro-Wilk</i> e <i>Mann-Whitney</i> entre pares de amostras RMSE para cada conjunto de dados de entrada	118
A.5	USIM5 - Testes de normalidade <i>Shapiro-Wilk</i> e <i>Mann-Whitney</i> entre pares de amostras RMSE para cada conjunto de dados de entrada	119
A.6	ABEV3 - Testes de normalidade <i>Shapiro-Wilk</i> e <i>Mann-Whitney</i> entre amostras de modelos LSTM e BiLSTM	121
A.7	B3SA3 - Testes de normalidade <i>Shapiro-Wilk</i> e <i>Mann-Whitney</i> entre amostras de modelos LSTM e BiLSTM	122
A.8	ITUB4 - Testes de normalidade <i>Shapiro-Wilk</i> e <i>Mann-Whitney</i> entre amostras de modelos LSTM e BiLSTM	123
A.9	PETR4 - Testes de normalidade <i>Shapiro-Wilk</i> e <i>Mann-Whitney</i> entre amostras de modelos LSTM e BiLSTM	124
A.10	USIM5 - Testes de normalidade <i>Shapiro-Wilk</i> e <i>Mann-Whitney</i> entre amostras de modelos LSTM e BiLSTM	125
A.11	ABEV3 - Testes de normalidade <i>Shapiro-Wilk</i> e <i>Mann-Whitney</i> entre amostras de modelos com/sem atenção	127
A.12	B3SA3 - Testes de normalidade <i>Shapiro-Wilk</i> e <i>Mann-Whitney</i> entre amostras de modelos com/sem atenção	128

A.13 ITUB4 - Testes de normalidade <i>Shapiro-Wilk</i> e <i>Mann-Whitney</i> entre amostras de modelos com/sem atenção	129
A.14 PETR4 - Testes de normalidade <i>Shapiro-Wilk</i> e <i>Mann-Whitney</i> entre amostras de modelos com/sem atenção	130
A.15 USIM5 - Testes de normalidade <i>Shapiro-Wilk</i> e <i>Mann-Whitney</i> entre amostras de modelos com/sem atenção	131
A.16 Importância e correlação de parâmetros do modelo no valor de RMSE nos dados de validação	132
A.17 Análise agregada do impacto do fator de células na média de RMSE dos modelos	133
A.18 Análise agregada do impacto da quantidade de camadas na média de RMSE dos modelos	133

Sumário

1	Introdução	19
1.1	Motivação	20
1.2	Objetivos do trabalho	22
1.3	Contribuições do Trabalho	22
1.4	Organização do Trabalho	23
2	Revisão bibliográfica	24
2.1	Considerações sobre os trabalhos relacionados	28
3	Fundamentação teórica	29
3.1	Conceitos de mercado financeiro	29
3.2	Redes Neurais Recorrentes (RNN)	31
3.2.1	Long Short-Term Memory (LSTM)	33
3.2.2	Bidirectional Long Short-Term Memory (BiLSTM)	35
3.2.3	Mecanismo de atenção aplicado às redes LSTM e BiLSTM	35
3.3	Indicadores Técnicos	37
3.3.1	Médias móveis	37
3.3.2	<i>Relative Strength Index</i> - RSI	38
3.3.3	<i>Moving Average Convergence- Divergence</i> - MACD	40
3.3.4	Canal de Keltner	41
3.3.5	<i>On Balance Volume</i> - OBV	43
3.3.6	<i>Volume Weighted Average Price</i> - VWAP	44
3.4	CrITÉrio de Kelly	44
4	Metodologia	47
4.1	Banco de dados	49
4.2	Pré-processamento de dados	50
4.3	Análise estatística dos dados	51
4.4	Transformação dos dados e definição de dados de treinamento	52
4.5	Treinamento das redes neurais LSTM e BiLSTM	53
4.6	Análise estatística do desempenho dos modelos	55
4.7	Definição de regras do sistema de gestão de risco (SGR)	56
4.8	Implementação de estratégias automatizadas	59
4.8.1	Estratégia Buy low/Sell High	59

4.8.2	Estratégia <i>Act on opening</i>	60
4.8.3	Cruzamento de média (<i>Crossover</i>)	61
4.8.4	Cruzamento de duas médias móveis (<i>Double crossover</i>)	62
4.8.5	Cruzamento de três médias móveis (<i>Triple crossover</i>)	64
4.8.6	Estratégia baseada em RSI (<i>Relative Strength Index</i>)	66
4.8.7	Estratégia baseada em MACD (<i>Moving Average Convergence -Divergence</i>)	66
4.9	<i>Backtesting</i> e Análise de resultados	68
5	Análise dos Resultados	70
5.1	Análise estatística dos dados	70
5.2	Treinamento dos modelos de predição	75
5.3	Análise estatística do desempenho dos preditores	76
5.4	Implementação de estratégias automatizadas	78
5.5	Resultados do <i>Backtesting</i>	82
5.5.1	<i>Baselines</i>	83
5.5.2	Aplicação do Sistema de Gestão de Risco (SGR) sobre estratégias .	86
5.5.2.1	ABEV3	86
5.5.2.2	B3SA3	90
5.5.2.3	ITUB4	93
5.5.2.4	PETRA4	95
5.5.2.5	USIM5	102
5.6	Considerações Finais	105
6	Conclusão	108
	Referências	111
	Apêndice A Testes estatísticos dos modelos treinados	114
A.1	Análise do desempenho de modelos de acordo com dados de entrada	114
A.2	Desempenho de redes LSTM e BiLSTM	120
A.3	Desempenho da aplicação de mecanismo de atenção	126
A.4	Impacto dos parâmetros da estrutura do modelo no valor de RMSE	132
A.5	Boxplot de RMSE agrupado por tamanho da janela	133
	Apêndice B Análise estatística dos dados	137
B.1	Boxplot das variáveis de log-retorno	137
B.2	Mapas de calor da análise de correlação cruzada	140
B.3	Gráficos de distribuição e dispersão	145
B.4	Distribuição de retornos percentuais dos valores máximos e mínimos em relação à abertura	150

B.5	Distribuição de retornos percentuais do valor máximo em relação ao mínimo do dia	150
Apêndice C	Gráficos dos cenários para backtesting	156

Capítulo 1

Introdução

A palavra **risco** representa um conceito com diversas interpretações a depender do contexto no qual é utilizada. No senso comum, o conceito de risco é geralmente associado à possibilidade de que algo ruim aconteça, como retrata o [Dicionário de Cambridge \[2021\]](#). No contexto da área de administração, o [Dicionário de Merriam-Webster \[2021\]](#) define risco como a chance de uma aplicação financeira perder valor.

De maneira abrangente pode-se entender o risco como sendo a probabilidade de que o resultado de um evento seja diferente do esperado, tal como a norma ABNT NBR ISO 31000:2018 define: “risco é definido como o efeito da incerteza nos objetivos”. Há de se notar que um efeito é um desvio em relação ao esperado, podendo ser positivo ou negativo, criando ou resultando em oportunidades/ameaças. O risco é normalmente expresso em termos de fontes de risco, eventos potenciais e suas consequências ou probabilidade.

Na área financeira, especificamente no tema de investimentos, a fonte do risco pode materializar-se em três principais componentes: crédito, liquidez e mercado.

O Conselho Monetário Nacional do Brasil (CMN) define o risco de crédito como “a possibilidade de ocorrência de perdas associadas ao não cumprimento pelo tomador ou contraparte de suas respectivas obrigações financeiras nos termos pactuados...” ([CMN \[2021\]](#)). A título de exemplo, quando um investidor compra um título de dívida de uma empresa (conhecido por *debênture*) ou do governo (títulos público), ele está na realidade emprestando dinheiro para esses tomadores e sujeito, portanto, ao risco de crédito que é a probabilidade de que os tomadores não paguem o retorno financeiro esperado.

Ainda segundo o CMN (Resolução 4.090/2012), o risco de liquidez é definido como “possibilidade de uma instituição não ser capaz de honrar suas obrigações esperadas e inesperadas, correntes e futuras e decorrentes de garantias, sem afetar suas operações diárias e sem incorrer em perdas significativas, além da possibilidade de não conseguir negociar a preço de mercado uma posição, em razão de alguma descontinuidade do mercado” ([CMN \[2021\]](#)). Pode-se exemplificar o risco de liquidez na seguinte situação: suponha que alguém possua patrimônio na forma de um imóvel e uma aplicação de poupança. Caso esta pessoa queira obter o valor financeiro desses dois investimentos, necessitará provavelmente de mais tempo para realizar a venda do imóvel do que sacar recurso da conta poupança. Entende-se, portanto, que a poupança é um investimento mais líquido do que

o imóvel. Além disso, se esta pessoa desejasse obter o valor financeiro do imóvel rapidamente talvez fosse obrigada a vender o imóvel por preço abaixo do valor de mercado, devido à baixa liquidez. No mercado de ações, uma ação pouco negociada é tratada como pouco líquida, devido à dificuldade de combinar um agente interessado em vender e outro em comprar. Desta forma, caso um investidor com um grande volume de ações deseje vender ao preço de mercado, para que haja total liquidação do volume, pode ser que as ações sejam negociadas a valores inferiores ao preço desejado. Situação análoga ocorre quando um investidor deseja comprar um volume muito grande de ações de uma só vez. Quando a expectativa do valor de venda de uma ação é muito maior que a expectativa do valor de compra, ou há pouco volume negociado em cada faixa de preço do ativo, este ativo possui maior risco de liquidez.

Por fim, segundo CMN [2021], o risco de mercado refere-se “a possibilidade de ocorrência de perdas resultantes da flutuação nos valores de mercado”. De forma mais abrangente, a oscilação de valores de mercados decorrem da volatilidade das negociações, ativos pouco líquidos sofrerão também de maior risco de mercado, as quais podem elevar ou reduzir bruscamente o valor negociado e, portanto, causar prejuízos ou grandes lucros a depender do posicionamento do investidor. Assim, o risco de mercado é geralmente quantificado pela volatilidade do preço do ativo, que pode ser calculada como o desvio padrão do valor do ativo em um período de tempo ou intervalo de oscilação do preço do ativo.

Percebe-se que o tema gestão de risco é central para o funcionamento do sistema financeiro, tais como fundos de investimentos e instituições financeiras (bancos e cooperativas de crédito), bem como para o sucesso de investidores, sejam profissionais ou amadores. Uma adequada gestão de risco permite maior chance de sucesso nos investimentos e a evolução do patrimônio ao longo do tempo.

A utilização de técnicas de aprendizado profundo para fins de gestão de risco é uma área ainda pouco explorada na literatura e, portanto, espera-se que este estudo explore o impacto dessas técnicas para gestão de risco de operações automatizadas (*algotrading*) na bolsa de valores.

1.1 Motivação

Uma das técnicas mais utilizadas para medir o risco de um portfólio ou ativo é o *VaR* - *Value at risk* (Morgan [1996]). Em linhas gerais, este método calcula a perda máxima esperada em um determinado período de tempo e nível de confiança. Por exemplo, suponha um investidor que tenha em seu portfólio R\$ 100 mil em ações de uma única

empresa e que tenha calculado um VaR mensal para esse portfólio com 95% de confiança de R\$ 2 mil. Isto significa que a cada mês há 95% de chance de que o portfólio desse investidor não perca mais que R\$ 2 mil de seu valor, e como seu portfólio consiste apenas nas ações de uma única empresa, esta mensuração de risco reflete em última instância o risco de mercado daquele ativo.

O *VaR* permite gerenciar o risco da perda esperada em um determinado intervalo de confiança, mas não fornece muita informação sobre a cauda da distribuição de probabilidade, que seriam, para o exemplo dado, os outros 5% dos eventos que poderiam levar a perdas maiores do que os R\$ 2 mil.

Diversos trabalhos têm sido apresentados utilizando técnicas de aprendizado de máquina e aprendizado profundo para prever a direção de movimento de um ativo no futuro. De certa forma, ao limitar a questão a um problema de classificação (preço do ativo sobe ou desce), estes trabalhos visam reduzir o risco de perda em investimentos realizados. Ao projetar que o valor de um ativo possa cair em um determinado horizonte de tempo, um investidor pode decidir não comprar o ativo naquele momento, caso sua estratégia seja de *buy-and-hold*, ou até mesmo realizar uma operação de venda a descoberto (*short*).

Outros trabalhos, porém, conforme será apresentado nos capítulos seguintes, focaram na previsão do preço de fechamento de ativos em um determinado horizonte de tempo. Este tipo de abordagem, a qual já trata o problema como uma regressão, permite apurar por meio do erro de predição e, de forma mais aprofundada, o resultado obtido. Estes trabalhos também possibilitam realizar uma gestão de risco de investimentos, mas ainda não estruturam sistematicamente o processo de previsão do valor em um arcabouço de sistema de gestão de risco.

Verifica-se, portanto, que a aplicação de algoritmos de aprendizado profundo para gestão de risco em investimentos é ainda uma área pouco explorada. A previsão do intervalo de variação futuro de preços (valor máximo e mínimo) relacionado a determinado ativo para fins de gestão de risco seria uma abordagem pioneira. Tal previsão poderia auxiliar o investidor sobre o momento mais adequado de iniciar uma operação de compra ou venda, ou no caso de sistemas automatizados de transação, selecionar as operações com maior chance de sucesso, a fim de maximizar os ganhos de cada operação sinalizada pela estratégia.

1.2 Objetivos do trabalho

O objetivo deste trabalho é estruturar um arcabouço modularizado de gestão de risco de operações automatizadas na bolsa de valores. Para isto, serão utilizadas arquiteturas e técnicas de aprendizado profundo, especificamente redes LSTM e BiLSTM, incorporando mecanismo de atenção, para prever o intervalo de valor de negociação (valor máximo e mínimo) de um determinado ativo no próximo período de tempo. O resultado desta predição será utilizado para selecionar as recomendações de abertura de posição que tenham maior chance de sucesso e retorno financeiro.

Assim, são objetivos específicos do trabalho:

- Realizar o estudo estatístico de 5 ativos mais representativos do índice IBOVESPA;
- Definir as variáveis de entrada para o treinamento de redes LSTM e BiLSTM;
- Obter as estruturas de redes otimizadas para predição dos preços máximo e mínimo de ativos;
- Realizar um estudo estatístico do desempenho de predição das redes treinadas, visando a criação de um sistema de gestão de risco;
- Simular o sistema de gestão de risco em estratégias automatizadas nos 5 ativos selecionados;
- Comparar o desempenho das estratégias automatizadas, com e sem a utilização do sistema de gestão de risco, a fim de verificar os benefícios da gestão de risco implementada.

1.3 Contribuições do Trabalho

Até onde o autor deste trabalho tem conhecimento, não há trabalhos que tratem da formulação de um sistema de gestão de risco (SGR) utilizando técnicas de aprendizado profundo para filtrar operações sugeridas por estratégias automatizadas.

Espera-se que a estruturação de um arcabouço de gestão de risco baseado em técnicas de aprendizado profundo seja uma contribuição relevante para o desenvolvimento da área de finanças computacionais. Ademais, ao abordar a gestão de risco de

forma modular, este trabalho poderá ser aplicado em qualquer estratégia automatizada de negociação e ser aperfeiçoado de forma modular.

Para fins de transparência e reprodutibilidade deste trabalho, todo código-fonte desenvolvido está disponível na plataforma Github pelo link <https://github.com/johnathas/dissertacao>.

1.4 Organização do Trabalho

Tendo sido realizada a introdução do tema da dissertação neste capítulo, bem como a motivação para o trabalho, o Capítulo 2 apresenta a revisão bibliográfica realizada e aborda os trabalhos relacionados ao tema de predição de séries temporais financeiras.

Em sequência, o Capítulo 3 apresenta os fundamentos e técnicas utilizadas para desenvolvimento do sistema de gestão de risco (SGR). Ao passo que o Capítulo 4 descreve cada etapa metodológica executada para construção desse sistema.

O Capítulo 5 demonstra os resultados obtidos no trabalho, bem como a análise desses, enquanto o Capítulo 6 encerra este documento com a conclusão do trabalho.

Todas as informações complementares foram inseridas em apêndices e anexos ao final da dissertação.

Capítulo 2

Revisão bibliográfica

Na literatura podem ser encontrados vários trabalhos que realizam revisão sistemática do uso de modelos de *machine learning* e *deep learning* em aplicações financeiras. Entre estes trabalhos, [Omer et al. \[2020\]](#) realizaram uma revisão da literatura, entre os anos 2005 e 2019, sobre estudos de aprendizado profundo aplicados à previsão de séries temporais financeiras, coletando 140 trabalhos ao todo. Estes trabalhos foram categorizados de acordo com o tipo de ativo previsto: preço de ação, previsão de movimento (sobe ou desce), previsão de índice, previsão de *forex*, *commodity*, previsão de volatilidade e previsão de criptomoedas. A maior parte dos estudos foi publicada a partir de 2017 e cerca de 70 % dos trabalhos analisados foram focados em previsão de preço de ações, índices ou tendência (problema de classificação). Os pesquisadores verificaram que os modelos recorrentes de redes neurais (RNN) são os mais utilizados para previsão de preço de ativos, sendo a arquitetura LSTM a mais empregada. Também identificou-se o uso de redes MLP (*Multilayer Perceptron*) e CNN (*Convolutional Neural Network*) para classificação de tendência. Por fim, entre as análises finais, os pesquisadores pontuaram que o uso de dados textuais, visando capturar o sentimento dos investidores e operadores de mercado (*traders*), foi uma tendência observada e que deve continuar atraindo interesse nos próximos anos.

Em um segundo trabalho mais específico para apresentar a situação atual do estado da arte de modelos de aprendizado profundo para aplicações financeiras, [Ozbayoglu et al. \[2020\]](#) analisaram 144 trabalhos nos 5 anos anteriores, coletados de *journals*, conferências, dissertações de mestrado, teses de doutorado e capítulos de livros. Os autores concluem que nos últimos 3 anos, além da previsão de séries temporais financeiras, os tópicos mais abordados foram mineração de textos financeiros e *algotrading*, seguidos de gestão de risco, análise de sentimentos, gestão de portfolio e detecção de fraudes. Foi observada a predominância no uso de modelos de rede neural recorrente (70% dos estudos utilizaram redes LSTM), seguido por DMLP e CNN.

[Jabbur \[2020\]](#) realizou um estudo dos principais trabalhos que envolveram aplicações no mercado de ação relativas à tratamento de dados, modelos de classificação de tendência e modelos de operação. Foram utilizados dados de cotação diária de 50 ativos da B3, bem como 10 índices globais com o objetivo de prever o movimento do dia seguinte por meio

de algoritmos de aprendizado de máquina para classificação. Utilizou-se dados entre 2010 e 2014 para treinamento dos modelos e dados entre 2015 e 2019 para validação. O autor implementou os algoritmos de Árvore Decisão J48, *Naive Bayes*, SVM, KNN (*K Nearest Neighbor*). Além disso, constatou o uso frequente na literatura de máquina restrita de Boltzmann (RBM) para extração de *features* de forma não supervisionada. Assim, foram realizados experimentos com os 4 modelos, com e sem a extração de *features* utilizando RBM, totalizando 8 modelos. Por meio de otimização, o autor verificou que o treinamento apresentou melhor resultados com uma janela deslizante de 20 dias e concluiu que o modelo RBM + *Naive Bayes* gerou o melhor resultado, apresentando precisão média de 50,45%, acurácia média de 52,75%, retorno financeiro bruto de 68,29%, sendo 17,01% maior que o *baseline buy-and-hold* (56,67%), avaliado para os 50 ativos e 10 índices.

Olorunnimbe and Viktor [2022] realizaram uma revisão sistemática da literatura sobre a utilização de modelos de aprendizado profundo em artigos de pesquisa que envolviam *backtesting*. A intenção dos autores foi de selecionar trabalhos que tivessem uma experimentação suficiente para que profissionais do mercado financeiro pudessem considerar como casos reais. Ao todo foram selecionados 35 trabalhos de 2018 a 2020, nos quais foi verificado que a maior parte dos estudos era focada em estratégias de negociação, predição de preço e gestão de portfólio (27 trabalhos), enquanto que uma parte pequena dos trabalhos centrou a pesquisa em simulação de mercado, seleção de ativos, estratégias de *hedging* e gestão de riscos (8 trabalhos, sendo apenas 1 categorizado como gestão de risco). Observou-se uma predomínio da utilização de redes LSTM em conjunção com aprendizado por reforço e utilização de taxas de retorno para avaliação de desempenho, principalmente nos trabalhos focados em estratégias de negociação (compra/venda baseado na predição de movimento futuro como um problema de classificação).

Ao debruçar sobre a tarefa de prever os valores futuros de séries temporais financeiras, tratando como um problema de regressão, uma equipe de pesquisadores realizou dois estudos em sequência, um para comparar modelos ARIMA com redes LSTM na predição de séries temporais financeiras (Siami-Namini et al. [2018]) e um segundo estudo para comparar o desempenho de predição univariável do preço de fechamento ajustado de um modelo ARIMA e das redes LSTM e BiLSTM, e avaliar aspectos no tratamento dos dados de entrada e impactos na convergência dos algoritmos. Utilizando dados do *Yahoo Finance* para os índices N225 (Nikkei 225 index), NASDAQ index, HSI, S&P Commodity index price (GSPC), DJIA e ações da IBM entre jan-1985 e aug-2018, e a função de perda RMSE e percentual de redução de RMSE para comparar os resultados. Os autores concluíram que os algoritmos de aprendizado profundo apresentaram melhor resultados que o modelo ARIMA. Além disso, a rede BiLSTM foi capaz de melhorar a acurácia em 37,78 % em relação à LSTM. Verificou-se que o processo de treinamento das redes BiLSTM é mais lento e pode utilizar *batches* menores que as redes LSTM. Como trabalho futuro, os autores indicaram a avaliação dos algoritmos para predição multivariada e séries sazonais.

Já [Selvin et al. \[2017\]](#) utilizaram técnicas de aprendizado profundo (RNN, LSTM e CNN) em uma janela deslizante de dados (com sobreposição) para identificar a dinâmica latente e prever os futuros valores de fechamento de um ativo no curto prazo. Das ações listadas na bolsa de valores da Índia foram escolhidas 3 empresas para realização do estudo, duas da área de TI e uma da área farmacêutica. Foi definida uma janela deslizante de 100 minutos, após testes de tamanho de janelas e seleção da janela que apresentava menor erro quadrático médio (RMSE), onde os primeiros 90 minutos eram usados como entrada dos modelos e os últimos 10 minutos consistiam na previsão fornecida pelos algoritmos. Os pesquisadores concluíram que os algoritmos de aprendizado profundo obtiveram menor erro de predição, tendo a CNN apresentado melhores resultados. Também acreditaram que, como no mercado de capitais ocorrem movimentos muito bruscos e a dinâmica altera-se ao longo do tempo, esses distúrbios não eram adequadamente tratados nos estados internos na RNN e LSTM, ao passo que a CNN, por não utilizar informação fora da janela deslizante, foi capaz de melhor prever os valores futuros. Contudo, o artigo não apresenta detalhes da estrutura da rede CNN utilizada.

Um trabalho que avançou no pré-processamento dos dados para treinamento dos modelos pode ser encontrado em [Qiu et al. \[2020\]](#), onde propuseram um modelo para previsão do preço de abertura de ativos por meio de uma rede LSTM com mecanismo de atenção, utilizando transformação *wavelet* nos dados para treinamento (WLSTM). O resultado é comparado com uma rede GRU e LSTM sem atenção. Como base de dados foram extraídos os preços de abertura, máximo, mínimo, fechamento e fechamento ajustado, a partir do Yahoo finance para S&P 500, DJIA e HSI (índice da bolsa de Hong Kong) entre jan-2000 e jul-2019. Por meio das métricas MSE, RMSE, MAE e R^2 , os autores concluíram que o modelo WLSTM com atenção apresentou melhores resultados. Como uma das direções de trabalhos futuros, os autores sinalizaram que o modelo poderia se beneficiar em termos de estabilidade e acurácia do uso de dados relacionados às notícias sobre ativos negociados devido aos eventos relevantes que não guardam relação com os dados históricos.

[Bao et al. \[2017\]](#) apresentou outro trabalho que demonstrou benefícios na utilização de transformação *wavelet* nas séries financeiras e afirmou o pioneirismo no uso de autoencoders empilhados para extração de *features* relevantes de dados OHLC (*Open-High-Low-Closing prices*) de forma não supervisionada, bem como a proposta de um arcabouço em três etapas para predição de séries temporais financeiras. O trabalho utiliza dados diários entre jul-2008 e set-2016 para 6 índices de ações: CSI 300 (China), Nifty 50 (Índia), HSI (Hong Kong), Nikker 225 (Japão), S&P 500 e DJIA (EUA), bem como 12 indicadores técnicos e variáveis macroeconômicas (taxa de câmbio em relação ao dólar e taxa de juros). O desempenho da predição foi realizado por meio das métricas MAPE, coeficiente R e Theil U, bem como realizado teste de rentabilidade por meio de estratégia *buy-and-sell* e *buy-and-hold*. O estudo concluiu que o novo arcabouço utilizando o

modelo de transformação *wavelet-autoencoders empilhados* e rede LSTM (WSAE-LSTM) demonstram estabilidade na predição, mesmo diante de condições de maturidade de mercados distintas, tendo apresentado retorno anual médio acima entre 45% e 64%, operando contratos futuros, e resultado melhor que os modelos WLSTM, LSTM e RNN.

[Kusuma et al. \[2019\]](#) utilizaram redes convolucionais (CNNs) em gráficos de *candles* para prever direção futura dos preços de ativos. Os autores realizaram experimentos em 50 ações negociadas em Taiwan e 10 ações do mercado da Indonésia. A metodologia consistiu em gerar figuras de gráficos de *candles* com 5, 10 e 20 dias de negociação, com e sem a informação de volume, e comparar o desempenho de redes de aprendizado profundo, tais como CNN, VGG (Visual Geometry Group) e redes residuais, com o desempenho de algoritmos tradicionais de aprendizado de máquina (*random forest* e *K-Nearest Neighbors*). Os autores identificaram que a informação de volume não melhorou o desempenho do modelo CNN e alegam que o modelo apresenta melhor acurácia quando aplicado sobre as mesmas bases de dados de outros modelos de trabalhos anteriores.

No que se refere a interdependência de bolsas ao redor do mundo, [Malagrino et al. \[2018\]](#) investigaram a viabilidade de redes bayesianas identificarem a influência de índices de outras bolsas na direção do IBOVESPA (alta ou baixa em relação ao fechamento anterior). Foram realizados testes com dados de 12 índices entre jun-2005 e abril-2012, em diferentes combinações de conjuntos de índices de bolsas em operação até 48 horas antes do fechamento do IBOVESPA. Os autores concluíram que o melhor resultado obtido foi uma acurácia de 75,49 %, utilizando os dados de fechamento dos índices NYSE Composite, CAC 40 e HSI.

[Fischer and Krauss \[2018\]](#) propõem uma estratégia de operação (*trading*) baseada em características comuns de ativos selecionados após treinamento de uma rede LSTM, obtendo retorno médio diário de 0,46 % antes dos custos de transação. O trabalho apresenta uma comparação criteriosa dos resultados de previsão da rede LSTM com algoritmo Random Forrest, DNN (*deep neural Network*) e classificador de regressão logística. Foram utilizados dados diários dos ativos do S&P obtidos da Thomson Reuters, entre jan-1990 e out-2015. A rede LSTM implementada previa a probabilidade do ativo apresentar ganho maior que a mediana, abrindo posição comprada nos n ativos com maior probabilidade de superar a mediana de ganho diário e posição vendida nos k ativos com menor probabilidade, segurando as posições por um dia. Os autores concluíram que a rede LSTM apresentou melhores resultados que demais algoritmos e identificaram que os ativos mais selecionados pela rede apresentavam características comuns de alta volatilidade, movimentos fortes de tendência em dias anteriores a operação e tendência de reversão no horizonte próximo.

2.1 Considerações sobre os trabalhos relacionados

Observa-se pelos trabalhos relacionados neste capítulo, principalmente nas revisões sistemáticas de literatura, que há um crescente uso de aprendizado profundo para aplicações financeiras. Ficou evidenciado nos trabalhos até então explorados a aplicação de *deep learning* em gestão de risco, mas não se verificou a aplicação específica em risco de mercado, o qual é tema central do trabalho proposto nessa dissertação.

Adicionalmente, ao utilizar redes LSTM e BiLSTM, vários trabalhos apresentaram melhores resultados que técnicas tradicionais de previsão de séries temporais financeiras ou algoritmos de aprendizado de máquina, o que reforça os possíveis benefícios do uso de aprendizado profundo (*deep learning*). No entanto, observa-se que a avaliação de desempenho dos preditores baseiam-se em métricas gerais, tais como RMSE, MSE, MAE, não sendo mais profundamente explorados a distribuição dos erros de predição.

Esta dissertação visa não apenas utilizar as redes LSTM e BiLSTM, mas também estruturar um arcabouço de análise estatística dos erros de predição desses modelos a fim de inferir regras parametrizáveis de um sistema de gestão de risco que irá calcular o risco envolvido em operações sugeridas por estratégias automatizadas.

É importante ressaltar ainda, que a estruturação do referido arcabouço será realizada de forma modular. Assim, os modelos de predição poderiam ser substituídos por outros que se deseje, bem como as estratégias automatizadas de operações. Assim, esta dissertação diferencia-se dos trabalhos relacionados à medida que busca unir o uso de técnicas de aprendizado profundo (*deep learning*) e a estruturação de uma análise estatística detalhada dos erros de predição, exergando estes dois componentes como módulos no desenvolvimento de um sistema de gestão de risco (SGR).

Capítulo 3

Fundamentação teórica

Neste capítulo serão apresentados os conceitos básicos utilizados no decorrer deste documento. A Seção 3.1 apresenta os conceitos de mercado financeiro, introduzindo termos comuns da área de negociação de ativos em bolsas de valores. A Seção 3.2 trata dos conceitos formais das redes de recorrência utilizadas na dissertação (LSTM e BiLSTM) e do mecanismo de atenção aplicado às redes neurais recorrentes. A Seção 3.3 apresentou os indicadores técnicos adotados no desenvolvimento do trabalho e por fim, a Seção 3.4 introduz o conceito de critério de Kelly utilizado para definição de exposição nas estratégias automatizadas de operações.

3.1 Conceitos de mercado financeiro

Antes de aprofundar no tema de gestão de risco, é conveniente introduzir algumas noções básicas do funcionamento das bolsas de valores.

Em termos bem simplificados, a bolsa de valores é um ambiente de intermediação financeira, no qual há mecanismos e instrumentos que permitem agentes, sejam pessoas físicas ou empresas, negociarem ativos financeiros.

Os ativos financeiros podem ser ações de empresas listadas naquela bolsa de valores ou derivativos, que são instrumentos financeiros que possuem algum ativo subjacente, por exemplo, índice futuro IBOVESPA.

Quando um investidor realiza, por exemplo, a compra de 300 ações de um ativo (em inglês, a operação de compra é referida como *long*), diz-se que ele está comprado naquele ativo e poderá a qualquer momento no futuro liquidar sua posição vendendo as ações que possui. No mercado financeiro, um investidor pode também realizar a venda de um ativo, sem necessariamente o possuir, esta operação chama-se venda à descoberto (*short*). Esse tipo de operação é utilizada quando o preço da ação está desvalorizando, permitindo ao investidor auferir lucro em operações financeiras nessa situação, bem como aumentar a liquidez do ativo, por meio do aumento da quantidade de negociações.

Quando um investidor realiza uma compra ou venda à descoberto, diz-se que ele está posicionado no ativo. Na B3, bolsa de valores sediada em São Paulo, o lote padrão de negociação de ações é de 100 ações. Há a possibilidade de realizar operações com quantidades menores que 100 no denominado mercado fracionário, no entanto, devido à demanda e oferta no mercado fracionário ser menor, há maior risco nas operações.

O conceito de *trade* refere-se ao processo de abrir posição de compra ou venda de ação, e em um momento futuro, zerar essa posição. No *trade* teremos informações de data e hora de abertura e fechamento de posição, quantidade de ações, preço médio de compra/venda e lucro/prejuízo. Quando um trade é realizado dentro de um dia de pregão (dia de operação da bolsa de valores) diz-se que foi um *trade* intradiário (*intraday*). A forma de operar na bolsa realizando operações no mesmo dia é conhecida como *daytrading*.

O sucesso de um *trade* depende, portanto, do ponto de entrada (preço pago pela ação ou preço no qual ação foi vendida) e da administração da operação que culmina no encerramento da posição. Pode-se utilizar diversos critérios diferentes para iniciar uma posição em uma ação, bem como basear-se em indicadores técnicos que sugiram sinais de entradas ou saídas nos ativos, podendo-se citar médias móveis, Banda de *Bollinger*, Canal de Keltner, Índice de Força Relativa (Relative Strength Index, RSI em inglês), entre outros. Quando as operações de compra e venda são sugeridas por um sistema baseado em regras que podem estar ou não fundamentadas em indicadores técnicos, denominamos de *algotrading* (*algorithmic trading*), o qual pode estar automatizado (gerindo as ordens de compra/venda de forma autônoma) ou não.

Uma vez iniciada uma operação, digamos de compra, o valor do ativo pode andar a favor da operação, no caso valorizar-se ou andar contra, desvalorizando-se. Quando a segunda situação ocorre, diz-se que a operação está em *drawdown*. Quanto maior o *drawdown* de uma operação, mais provável é que a operação tenha sido mal sucedida e acarretará em prejuízo ao investidor.

Assim, interessa ao investidor entrar em operações que não tenham *drawdown*, ou seja, que andem a favor da leitura realizada. Se foi feita uma operação de compra, espera-se que o ativo valorize-se e que renda lucro na operação.

A fim de evitar prejuízos maiores, pode-se utilizar de operações denominadas *stoploss* (ou *stop*), que nada mais são que operações inversas à posição do investidor em um preço pré-calculado que limite a perda de seu patrimônio naquela operação. Trata-se, portanto, de um instrumento para lidar com o risco de mercado devido à volatilidade do preço do ativo ou uma leitura equivocada do mercado no momento de abrir a posição.

Um tipo de *stoploss* utilizado no mercado é o *trailing stop*, que é um mecanismo que visa proteger ganhos já conquistados após a abertura de uma posição. Por exemplo, pode-se configurar um *trailing stop* para se inicie com um *stop* 5 centavos abaixo do preço da posição comprada do investidor, e para cada 3 centavos que o ativo andar a favor da operação (valorizar-se), esse *stop* eleve-se em 1 centavo. Assim, ao invés de ter um *stoploss*

fixo, ele caminha junto com a operação, de tal forma que, se houver uma mudança no mercado e o ativo começar a desvalorizar mais do que o previsto, a operação pode ser encerrada com menor prejuízo ou até mesmo com lucro. Observe que neste exemplo, se o investidor tivesse comprado uma ação à R\$ 10,00, seu *stop* inicial estaria em R\$ 9,95. Se a operação sofresse *drawdown* de 2 centavos no preço do ativo e em seguida valoriza-se 23 centavos de forma linear, o *stop* iria ser atualizado para R\$ 10,02, preço acima do valor comprado e, portanto, esta operação não causaria mais prejuízo ao investidor.

Um investidor prudente está sempre atento à gestão de seu patrimônio, não se envolvendo em riscos demasiados que possam reduzir seu capital de forma abrupta. Assim, o tamanho da posição em uma operação reflete a sua exposição ao risco. Quanto menor o risco de perda ou maior a expectativa de ganho, maior seria o tamanho da posição.

De posse de um histórico de operações, é possível calcular estatísticas, tais como taxa de acerto/sucesso de *trades* e relação risco/ganho, que permitem auxiliar o processo de definição do tamanho das posições em futuras operações.

Um Sistema de Gestão de Risco (SGR) deveria, portanto, filtrar as operações sugeridas por diferentes sistemas de *algotrading*, visando minimizar a probabilidade de *drawdown* e prejuízos acima de limites pré-estabelecidos, bem como aumentar a taxa de acerto e relação risco/ganho e maximizar o retorno das operações realizadas.

A Figura 3.1 ilustra o conceito central desse trabalho e do Sistema de Gestão de Risco proposto. Nela são apresentadas regiões de operação de compra/venda do ativo as quais foram indicadas pelo modelo de predição do SGR que utiliza algoritmo *deep learning*, mais especificamente, redes LSTM e BiLSTM. Suponha que haja uma estratégia automatizada gerando sinais de compra (C) e venda (V) para o investidor operar aquele ativo. O SGR atuará então como um sistema de 2º nível, permitindo apenas a abertura de posições dentro dentro das regiões indicadas (operações em verde). Espera-se que a utilização do SGR sobre a estratégia potencialize o retorno financeiro daquela estratégia.

3.2 Redes Neurais Recorrentes (RNN)

Segundo Trevor Hastie [2009], redes neurais recorrentes (RNN) são um tipo de rede neural projetadas para lidar com dados sequenciais ou séries temporais de dados. Assim, essas redes, também classificadas como algoritmos de aprendizagem profunda (*deep learning*), são frequentemente utilizadas para problemas de tradução, processamento de linguagem natural, reconhecimento de fala, geração automatizada de legendas e previsão de valores futuros de séries temporais.

As RNNs diferenciam-se de outros algoritmos *deep learning* devido a sua capaci-

Figura 3.1: Exemplo da aplicação de SGR sobre uma estratégia arbitrária de *algotrading* ilustrando a ideia central deste trabalho



Fonte: Gráfico anotado pelo autor com dados extraídos do site www.tradingview.com (2022)


dade de reter memória de estados anteriores das entradas e da própria rede neural para prever a saída atual, pois visam resolver problemas nos quais as entradas ao longo do tempo não são assumidas como independentes entre si.

A Figura 3.2 apresenta a arquitetura básica de uma rede neural recorrente. Do lado esquerdo, encontra-se a diagramação compacta da rede RNN, no qual há uma camada de entrada, uma camada escondida e uma camada de saída. Observa-se que a camada escondida possui uma retroalimentação. A diagramação expandida da RNN (apresentada no lado direito) exhibe cada variável das camadas de entrada e saída, bem como demonstra que a retroalimentação da camada escondida ocorre por meio de informação compartilhada entre os blocos da camada.

Uma característica distinta das RNNs é que os pesos são compartilhados entre todos os blocos de cada camada, enquanto outras redes de aprendizado profundo treinam diferentes pesos para cada nó da rede. Não obstante, nas duas situações os pesos são ajustados pelo mesmo processo de retropropagação (*backpropagation*) e método de gradiente (*Gradient descent*).

Devido à característica de lidar com dados sequenciais, o processo de treinamento das RNNs é denotado por BPTT (*backpropagation through time*) e é um pouco diferente do tradicional *Backpropagation*, pois enquanto o último não compartilha o erro entre as

Figura 3.2: Diagrama esquemático da arquitetura de Redes Neurais Recorrentes



Fonte: www.ibm.com/cloud/learn/recurrent-neural-networks (site visitado em 28/02/2022)

camadas, no BPTT acumula o erro para cada passo dentro da camada. Desta forma, dois problemas conhecidos no processo de treinamento de RNNs são: explosão de gradiente (*exploding gradient*) e *vanishing gradient*. Estes problemas surgem devido ao tamanho do gradiente. Quando o gradiente fica muito pequeno, o algoritmo reduz significativamente a aprendizagem, ao passo que quando o gradiente se torna muito grande, o treinamento do modelo é instável, podendo não convergir.

Uma variação das RNNs, que são unidirecionais, pois a informação flui dos estados anteriores para os próximos, são as redes recorrentes bidirecionais (BRNN). Nas BRNNs, os dados de entrada e estados internos posteriores são também utilizados para geração da saída corrente na expectativa de melhorar o desempenho da rede neural.

Uma arquitetura de RNN bastante conhecida e utilizada na literatura é a LSTM (Long Short-Term Memory), à qual foi posteriormente incorporada o bidirecionamento, resultando na BiLSTM. Estas arquiteturas serão explicadas nas seções seguintes.

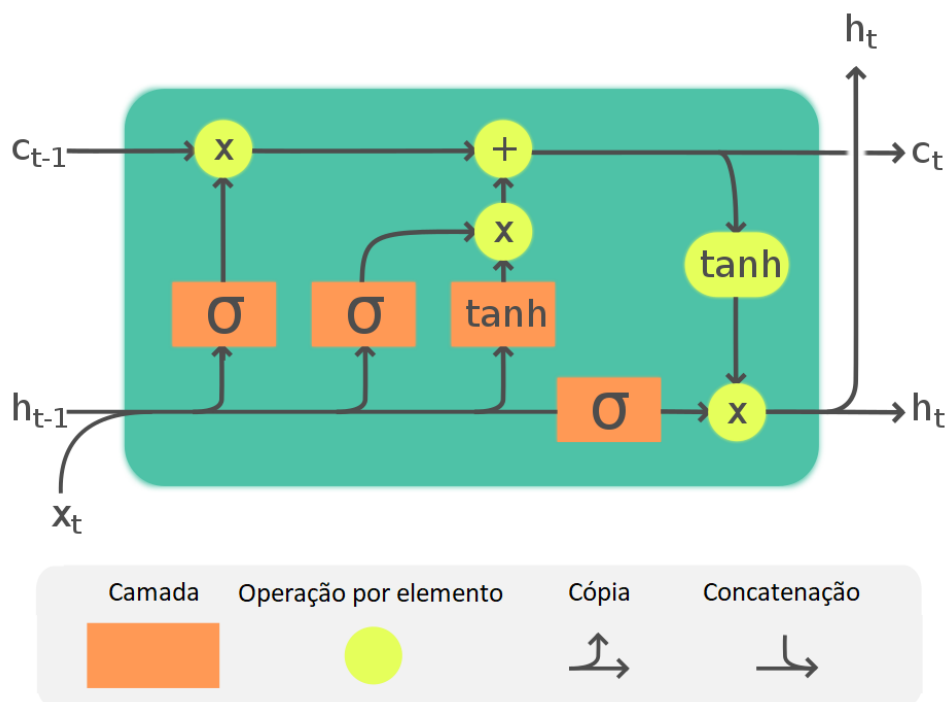
3.2.1 Long Short-Term Memory (LSTM)

Em março de 1997, Sepp Hochreiter e Juergen Schmidhuber propuseram as redes LSTMs como solução para o problema de *vanishing gradient* e dependências de longo

prazo entre os dados (Hochreiter and Schmidhuber [1997]).

A versão original da rede LSTM foi modificada ao longo do tempo, sendo a versão mais comumente utilizada aquela que possui 3 portões (*gates*): *input*, *output* e *forget*, conforme apresentado na Figura 3.3.

Figura 3.3: Diagrama esquemático da estrutura de uma célula LSTM



Fonte: https://en.wikipedia.org/wiki/Long_short-term_memory (site visitado em 28/02/2022)

De forma sucinta, cada célula LSTM trata de um período de tempo (*timestamp*) e decide qual informação é irrelevante e pode ser esquecida (*forget gate* - f_t), adiciona ou atualização nova informação (*input gate* - i_t) e repassa informação para a célula do próximo período de tempo (*output gate* - o_t). Assim, o estado interno da célula LSTM do período de tempo t é h_t , bem como o estado da célula do período de tempo t é c_t . A entrada da célula do período t é x_t . Assim, conforme apresentado esquematicamente na Figura 3.3, as fórmulas que regem o funcionamento da célula LSTM são apresentadas na equação 3.1:

$$f_t = \sigma_g(W_f x_t + U_f h_{t-1} + b_f) \quad (3.1)$$

$$i_t = \sigma_g(W_i x_t + U_i h_{t-1} + b_i)$$

$$o_t = \sigma_g(W_o x_t + U_o h_{t-1} + b_o)$$

$$\tilde{c}_t = \sigma_c(W_c x_t + U_c h_{t-1} + b_c)$$

W_f , W_i , W_o , W_c são as matrizes de pesos associadas ao vetor de entrada dos

portões *forget*, *input*, *output* e do estado da célula, respectivamente, bem como U_f , U_i , U_o e U_c representam as matrizes de pesos das conexões recorrentes associadas aos estados internos das células LSTM. σ_g e σ_c são as funções de sigmóide e tangente hiperbólica.

Assim, as saídas da célula LSTM, quais sejam o estado da célula e o estado interno, são dadas pela Equação 3.2. Verifica-se que o estado da célula no período t é composto pela soma de dois produtos elemento-a-elemento. O primeiro refere-se ao *forget gate* com o estado da célula anterior ($t-1$) e o segundo ao *input gate* com o vetor de ativação da entrada da célula t . Já o estado interno da célula t é o produto elemento-a-elemento do *forget gate* e a função de tangente hiperbólica aplicada ao estado da célula t (c_t).

$$\begin{aligned} c_t &= f_t c_{t-1} + i_t \tilde{c}_t \\ h_t &= o_t \sigma_h(c_t) \end{aligned} \quad (3.2)$$

3.2.2 Bidirectional Long Short-Term Memory (BiLSTM)

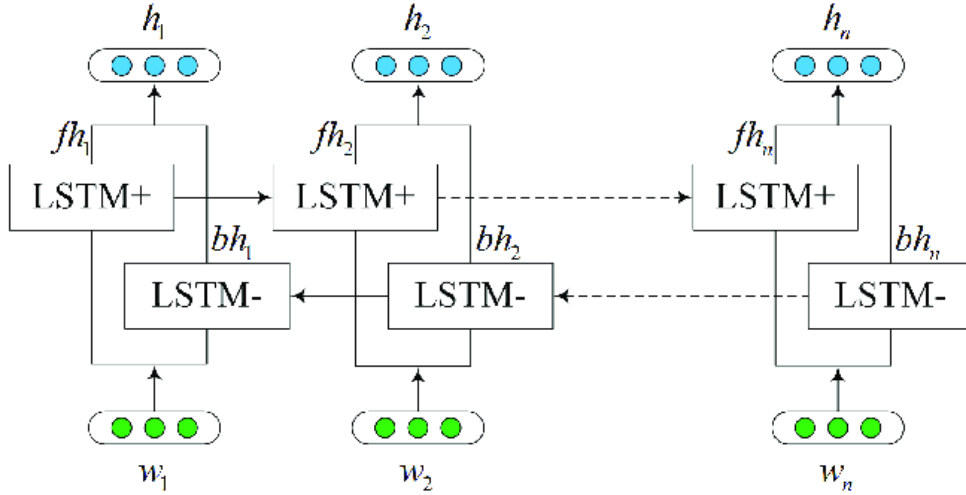
Proposta em novembro de 1997 por Mike Schuster e Kuldip K. Paliwal ([Schuster and Paliwal \[1997\]](#)), a rede BiLSTM difere-se de sua predecessora (LSTM) por utilizar informação tanto dos períodos de tempo anteriores quanto dos períodos de tempo futuros. Assim a rede BiLSTM é composta por duas redes LSTMs, onde uma delas realiza o fluxo de informação do passado para o futuro e a outra o fluxo de informação do futuro para o passado, conforme pode ser visto na Figura 3.4.

Devido à proposta de utilizar mais informação de contexto dos períodos de tempo anteriores e posteriores ao atual período de tempo da célula, as redes BiLSTM são comumente aplicadas a tarefas de processamento de linguagem natural, tais como: tradução, reconhecimento de escrita, marcação de *Part-of-speech (POS)*, extração de entidades, etc.

3.2.3 Mecanismo de atenção aplicado às redes LSTM e BiLSTM

O conceito de mecanismo de atenção foi apresentado pela primeira vez em 2015 na ICLR (*The International Conference on Learning Representations*), em um trabalho relacionado à tradução de texto no qual foi apresentado um mecanismo automatizado de selecionar partes mais importantes de uma sentença para prever a próxima palavra,

Figura 3.4: Diagrama esquemático da estrutura de uma rede BiLSTM



Fonte: Xie et al. [2019]

utilizando modelos BiLSTM na estrutura de encoder-decoder Bahdanau et al. [2016]. Embora o termo mecanismo de atenção tenha sido utilizado apenas 3 vezes no artigo, esta técnica ganhou bastante relevância devido à melhoria significativa de desempenho nas tarefas processamento de linguagem natural.

O diferencial desta técnica foi permitir ao modelo aprender quais estados internos são mais relevantes para realizar a predição de cada item da sequência de saída do modelo. A Figura 3.5 ilustra a ideia básica do mecanismo de atenção.

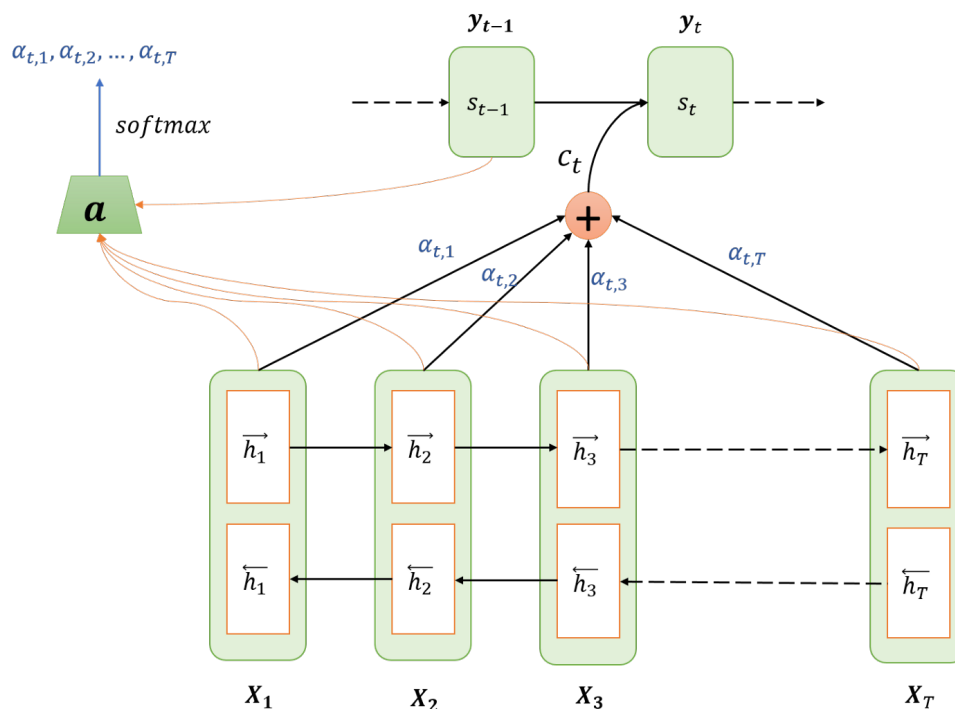
Na prática, o mecanismo de atenção pode ser visto como uma camada que recebe como entrada um vetor contendo os estados internos de cada célula LSTM da camada anterior, aplica uma função de ativação de tangente hiperbólica para escalar os estados, em seguida aplica uma função *softmax*, gerando a saída para a próxima camada da rede. A Equação 3.3 apresenta os cálculos de uma camada de atenção.

$$f_{tj} = \sigma(W_h h_t + b_h), \forall j \in [1, T] \quad (3.3)$$

$$\alpha_{tj} = \frac{e^{f_{tj}}}{\sum_{k=1}^T e^{f_{tk}}}$$

W_h é a matriz de pesos associada ao vetor de estados internos das células LSTMs/BiLSTMs (h_t). σ é uma função de ativação tangente hiperbólica e α_{tj} são os pesos calculados da função *softmax*.

Figura 3.5: Diagrama esquemático do mecanismo de atenção aplicado a rede BiLSTM



Fonte: [https://shashank7-iitd.medium.com/](https://shashank7-iitd.medium.com/understanding-attention-mechanism-35ff53fc328e)

[understanding-attention-mechanism-35ff53fc328e](https://shashank7-iitd.medium.com/understanding-attention-mechanism-35ff53fc328e) (site visitado em 08/03/2022)

3.3 Indicadores Técnicos

A seguir serão apresentados os indicadores técnicos que foram utilizados no desenvolvimento deste trabalho.

3.3.1 Médias móveis

As médias móveis são bastante utilizadas em sistemas de rastreamento de tendência (*trend-following*). No entanto, é importante ressaltar que pela natureza de seu cálculo são indicadores que estão sempre atrasados e nunca adiantados em relação à variável medida. Ao realizar a média de n períodos passados de uma variável, a curva da média tende a ser mais suave a medida que n aumenta, bem como apresentará maior atraso na exibição de alguma tendência de movimento.

Os dois tipos de médias móveis mais utilizadas na área de finanças são: média simples e média exponencial. A média simples de n períodos passados de uma variável

aplica o mesmo peso a todos os instantes de tempo, consistindo, portanto, em uma média aritmética na qual é considerada apenas a informação dos n períodos. A Equação 3.4 apresenta a fórmula de cálculo da média simples para n últimos períodos.

$$SMA_t = \frac{1}{n} \sum_{i=1}^n P_{t-i} \quad (3.4)$$

Já a média exponencial visa atribuir peso maior aos instantes de tempo mais recentes. Apesar de usar pesos menores para instante de tempo mais distantes, a média móvel exponencial utiliza todos os dados passados da variável. A Equação 3.5 apresenta a fórmula de cálculo da média móvel exponencial.

$$EMA_t = P_{t-1}M + EMA_{t-1}(1 - M) \quad (3.5)$$

onde M é um multiplicador utiliza-se para ponderar as observações mais recentes.

Geralmente utiliza-se a seguinte fórmula para o cálculo da média móvel exponencial dos últimos n períodos: $M = 2/(n + 1)$. Caso deseje-se calcular, por exemplo, a média móvel exponencial do preço de fechamento dos últimos 10 períodos, o valor de M seria 18,18%. Desta forma, o último preço de fechamento teria peso de 18,18% do valor da média móvel exponencial, sendo o restante distribuído decrescentemente para os preços de fechamentos passados.

A Figura 3.6 apresenta um gráfico no qual foram plotadas as médias móveis simples e exponencial do preço de fechamento dos últimos 10 períodos. Observa-se que a média móvel exponencial tende a reagir mais rapidamente aos movimentos recentes de preço do que a média móvel simples.

3.3.2 *Relative Strength Index - RSI*

O Índice de Força Relativa (IFR), ou em seu acrônimo em inglês RSI (*Relative Strength Index*) foi desenvolvido por J. Welles Wilder Jr. e apresentado em seu livro *New Concepts in Technical Trading Systems* em 1987.

O RSI é um indicador da classe de osciladores (Equação 3.6), seu valor varia de 0 a 100 e foi originalmente proposto utilizando janela dos últimos 14 períodos para cálculo do RS.

$$RSI = 100 - \frac{100}{1 + RS} \quad (3.6a)$$

$$RS = \frac{\text{Média de ganho nos dias de alta}}{\text{Média de perda nos dias de baixa}} \quad (3.6b)$$

Figura 3.6: Gráfico exemplificativo da diferença de utilização de médias móveis simples e exponencial do preço de fechamento dos últimos 10 períodos para o ativo ABEV3



Fonte: Gráfico elaborado pelo autor no site www.tradingview.com (2022)

Caso deseje-se aplicar o indicador para operações curtas, utiliza-se uma janela menor de dados, o que aumentará a volatilidade do valor do RSI calculado. Caso deseje-se aplicar em operações longas, basta utilizar uma janela de dados maior, o que causará um efeito de suavização na curva do RSI.

A região acima de 70 caracteriza pela condição de sobrecompra do ativo, enquanto a região abaixo de 30 é caracterizada pela condição de sobrevenda do ativo. O limite superior e inferior para caracterização de sobrecompra e sobrevenda pode ser otimizado para cada ativo, podendo assumir valores diferentes tais como 80 e 20, por exemplo.

A interpretação do RSI consiste em identificar falhas no oscilador. Uma falha de topo do RSI ocorre quando, em uma tendência de alta no preço dos ativos, um novo pico é formado na região de sobrecompra, porém com valor menor do que o pico anterior, seguido de um cruzamento do limite de sobrecompra para baixo. Uma falha de fundo ocorre de forma análoga, ou seja, em uma tendência de baixa no preço dos ativos, um novo fundo é formado na região de sobrevenda, porém com valor maior do que o fundo anterior, seguido de um cruzamento do limite de sobrevenda para cima. Essa divergência de tendência entre o preço do ativo e o valor do RSI devem ser considerados como sinais

Figura 3.7: Exemplo do indicador RSI aplicado ao ativo USIM5



Fonte: Gráfico elaborado pelo autor no site www.tradingview.com (2022)

de atenção para possível reversão de tendência do preço do ativo.

3.3.3 *Moving Average Convergence-Divergence* - MACD

O indicador MACD (*Moving Average Convergence-Divergence*) foi desenvolvido por Gerald Appel no final dos anos de 1970. Este indicador bastante popular no mercado financeiro utiliza-se de médias móveis e princípios de osciladores.

Uma linha rápida, definida como linha MACD consiste na diferença entre duas médias móveis exponenciais do preço de fechamento dos ativos, comumente adotados os períodos de 12 e 26. Uma linha mais lenta, denominada sinal, consiste na média móvel exponencial da linha MACD utilizando 9 períodos.

A região de sobrecompra consiste em valores bem acima de zero, enquanto a região de sobrevenda consiste em valores bem abaixo de zero. Divergências aparecem entre a tendência do valor do MACD e o preço do ativo. Uma divergência negativa ou baixista, ocorre quando o MACD está na região de sobrecompra e inicia uma tendência de baixa

(em direção à zero) enquanto o preço dos ativos continua a ser negociado em valores mais altos. Isto geralmente cria um alerta para um topo no mercado. Por outro lado, uma divergência positiva ou altista, ocorre quando o MACD está na região de sobrevenida e inicia uma tendência de alta (em direção à zero) enquanto o preço dos ativos continua a ser negociado em valores mais baixos, caracterizando um alerta para um fundo no mercado.

É bastante comum a utilização de histograma para visualizar o valor de MACD, pois facilita verificar a expansão ou compressão da diferença das médias de 12 e 26 períodos. A Figura 3.8 apresenta um exemplo do indicador MACD.

Figura 3.8: Exemplo do indicador MACD aplicado ao ativo ABEV3



Fonte: Gráfico elaborado pelo autor no site www.tradingview.com (2022)

3.3.4 Canal de Keltner

O Canal de Keltner foi inicialmente apresentado por Chest Keltner em 1960 em seu livro *How to make money in commodities*. Trata-se de um indicador baseado em uma média móvel como linha central e dois envelopes acima e abaixo desta linha.

As ideias expostas naquele livro foram trabalhadas ao longo do tempo de tal forma

que a versão atualmente popularizada do Canal de Keltner utiliza como linha central uma média móvel exponencial do preço de fechamento, por exemplo dos últimos 12 períodos, e como envelopes um múltiplo da média dos intervalos entre o preço máximo e mínimo dos últimos 12 períodos, usualmente o múltiplo 2.

O indicador visa identificar regiões de sobre compra e sobrevenda do ativo, que seriam acima do envelope superior e abaixo do envelope inferior, respectivamente. Durante uma tendência clara, seja de alta ou baixa, o rompimento dos envelopes é visto como um sinal de força do movimento. No entanto, em situações de consolidação após o cruzamento com um envelope, é esperado o movimento de retorno à média (linha central do canal).

A Figura 3.9 apresenta um exemplo da aplicação do Canal de Keltner ao ativo PETR4 utilizando como linha central a média móvel exponencial do preço de fechamento nos últimos 12 períodos e como envelopes duas vezes o valor médio do intervalo preço máximo-mínimo dos últimos 12 períodos.

Figura 3.9: Exemplo de Canal de Keltner aplicado ao ativo PETR4



Fonte: Gráfico elaborado pelo autor no site www.tradingview.com (2022)

3.3.5 *On Balance Volume - OBV*

Criado em 1963 por Joe Granville e apresentado pela primeira vez no livro *Granvilles's new key yo stock market profits*, o indicador *On Balance Volume* (OBV) é um indicador cumulativo concebido para mensurar a pressão compradora ou vendedora sobre um ativo. Se o preço do ativo sobe em determinado período, o volume daquele período é somado ao valor acumulado OBV, caso o preço do ativo caia, o volume negociado no período é subtraído do valor acumulado OBV.

A teoria fundamental do OBV é que o aumento do volume de negociação ocorre antes de um movimento relevante de preço do ativo. Assim, este indicador é geralmente utilizado para antecipar movimentos de preço após alguma divergência ser identificada (quando o movimento de preço não é confirmado pelo indicador), ou confirmar tendência no mercado.

A Figura 3.10 apresenta um exemplo do calculo do indicador OBV para o ativo ITUB4.

Figura 3.10: Exemplo do indicador OBV aplicado ao ativo ITUB4



Fonte: Gráfico elaborado pelo autor no site www.tradingview.com (2022)

3.3.6 *Volume Weighted Average Price - VWAP*

O VWAP é, basicamente, uma média ponderada do preço do ativo pelo volume negociado, e é geralmente utilizado para gráficos intradiários para determinar a tendência de movimento. O preço de referência a ser ponderado em cada período pode ser o preço de fechamento ou a média simples dos preços máximo, mínimo e fechamento do período, por exemplo. Geralmente, calcula-se o VWAP para uma janela temporal, utilizando os dados de preço e volume apenas do dia, da semana, do mês, etc.

Assim como as médias móveis, o VWAP está sempre atraso em relação ao preço do ativo. Em uma tendência de alta, o preço do ativo deve estar acima do VWAP, enquanto que em uma tendência de baixa, o preço do ativo deve estar abaixo da VWAP. Em uma situação de consolidação, o preço tende a cruzar repetidamente a linha de VWAP.

A Equação 3.7 apresenta a fórmula de cálculo do indicador, ao passo que a Figura 3.11 apresenta um exemplo do VWAP diário do ativo B3SA3 utilizando como preço de referência a média simples do valor máximo, mínimo e fechamento de cada período.

$$\text{VWAP}_t = \frac{\sum P_{ref,t} V_t}{\sum V_t} \quad (3.7)$$

onde $P_{ref,t}$ é o preço de referência no período t e os somatórios referem-se aos períodos da janela temporal desejada.

3.4 Critério de Kelly

Em 1956, um cientista norte-americano da AT&T Bell Labs chamado John Larry Kelly Jr. publicou um trabalho intitulado *A new interpretation of information rate* (J. L. Kelly [1956]) para lidar com problemas de ruído em transmissões telefônicas de longas distâncias. No entanto, os especuladores perceberam a utilidade e a analogia do trabalho na área de apostas e finanças como uma forma de maximizar o crescimento do capital ao longo do tempo.

Basicamente, a fórmula desenvolvida por Kelly visa calcular o tamanho de uma aposta dada uma probabilidade já conhecida de sucesso e uma taxa de risco/ganho, de forma a maximizar o patrimônio caso sejam realizadas infinitas apostas em sequência. A Equação 3.8 apresenta a fórmula de Kelly:

$$K\% = W - \frac{1 - W}{R} \quad (3.8)$$

Figura 3.11: Exemplo do indicador VWAP diário aplicado ao ativo B3SA



Fonte: Gráfico elaborado pelo autor no site www.tradingview.com (2022)

onde $K\%$ é o tamanho da aposta em relação ao capital disponível, W é a taxa de acerto e R o risco/ganho.

No contexto das finanças, de forma prática, geralmente utiliza-se uma amostragem de 50 a 60 operações para calcular a taxa de acerto, bem como calcular o risco/ganho, somando-se o lucro das operações bem sucedidas e dividindo pelo módulo da soma do prejuízo das operações fracassadas.

A aplicação prática da fórmula de Kelly gera algumas críticas, pois é pouco provável alcançar o ótimo calculado teoricamente, uma vez que há incerteza no valor da taxa de sucesso, podem haver restrições adicionais na gestão do capital (por exemplo, não perder mais do que 30% do patrimônio) e a série de apostas ou operações é limitada. Estas questões já haviam sido endereçadas pelo Kelly em seu artigo ao afirmar haver necessidade de definir uma função de utilidade no caso de recorrências limitadas. Assim, como o valor teórico de Kelly pode gerar grande volatilidade, é usual adotar como tamanho da aposta uma fração do valor de Kelly, por exemplo $1/4$, $1/3$ ou $1/2$ Kelly (Thorp et al. [2010]).

Para exemplificar, vamos supor que em uma determinada operação de compra/venda de ativo na bolsa de valores, caso o investidor tenha sucesso, ele recebe um retorno de 130% do capital investido, caso a operação não seja bem sucedida, ele perde 15% do capital. Assim, a relação risco/ganho é $30\%/15\% = 2$. Sabe-se ainda, pelo histórico de

operações que a probabilidade de sucesso é 45%. Logo, a fórmula de Kelly resulta que para maximizar os ganhos no longo prazo, este investidor deveria fazer cada operação com 17,5% de seu capital. No entanto, este tamanho de posição pode estar em desacordo com o apetite de risco do investidor e uma sequencia inicial de fracassos poderia levar a uma perda drástica do patrimônio. Desta maneira, um valor mais prudente e menos sujeito a volatilidade no resultado final seria uma posição de 8,75% (1/2 Kelly) ou até mesmo 5,8% (1/3 Kelly).

Capítulo 4

Metodologia

Este capítulo descreve o processo metodológico aplicado no desenvolvimento do Sistema de Gestão de Risco (SGR) proposto nesta dissertação e representado pela Figura 4.1, a qual relaciona as etapas executadas. Cada seção deste capítulo descreverá detalhadamente os aspectos relevantes das etapas da metodologia.

O primeiro passo da metodologia, apresentado na Seção 4.1, introduz os detalhes relativos aos dados coletados para desenvolvimento do trabalho e justificativa dos ativos selecionados para obtenção dos resultados. Na sequência, o passo 2 (Seção 4.2) fornece informação sobre como os dados foram processados para serem utilizados no treinamento dos modelos de aprendizado profundo. A Seção 4.3, referente ao passo 3 da metodologia, apresenta as análises estatísticas aplicada sobre os dados a fim de adquirir maior conhecimento sobre os mesmos.

No passo 4 (Seção 4.4) o leitor terá acesso à definição dos conjuntos de dados utilizados como dados de entrada para treinamento das redes LSTM e BiLSTM. Em seguida, a Seção 4.5 detalha como os modelos foram treinados e métricas utilizadas para avaliação do desempenho dos modelos e seleção do modelo de predição a ser utilizado nas etapas subsquentes para cada ativo.

A etapa referente à análise estatística de desempenho dos modelos (etapa 6) é apresentada na Seção 4.6, a qual aborda os testes estatísticos realizados sobre a distribuição de erros percentuais de predição dos modelos selecionados.

A definição de regras do sistema de gestão de risco (SGR) é abordada na etapa 7 da metodologia (Seção 4.7), a qual apresenta o algoritmo do SGR e justifica as decisões tomadas na implementação do sistema.

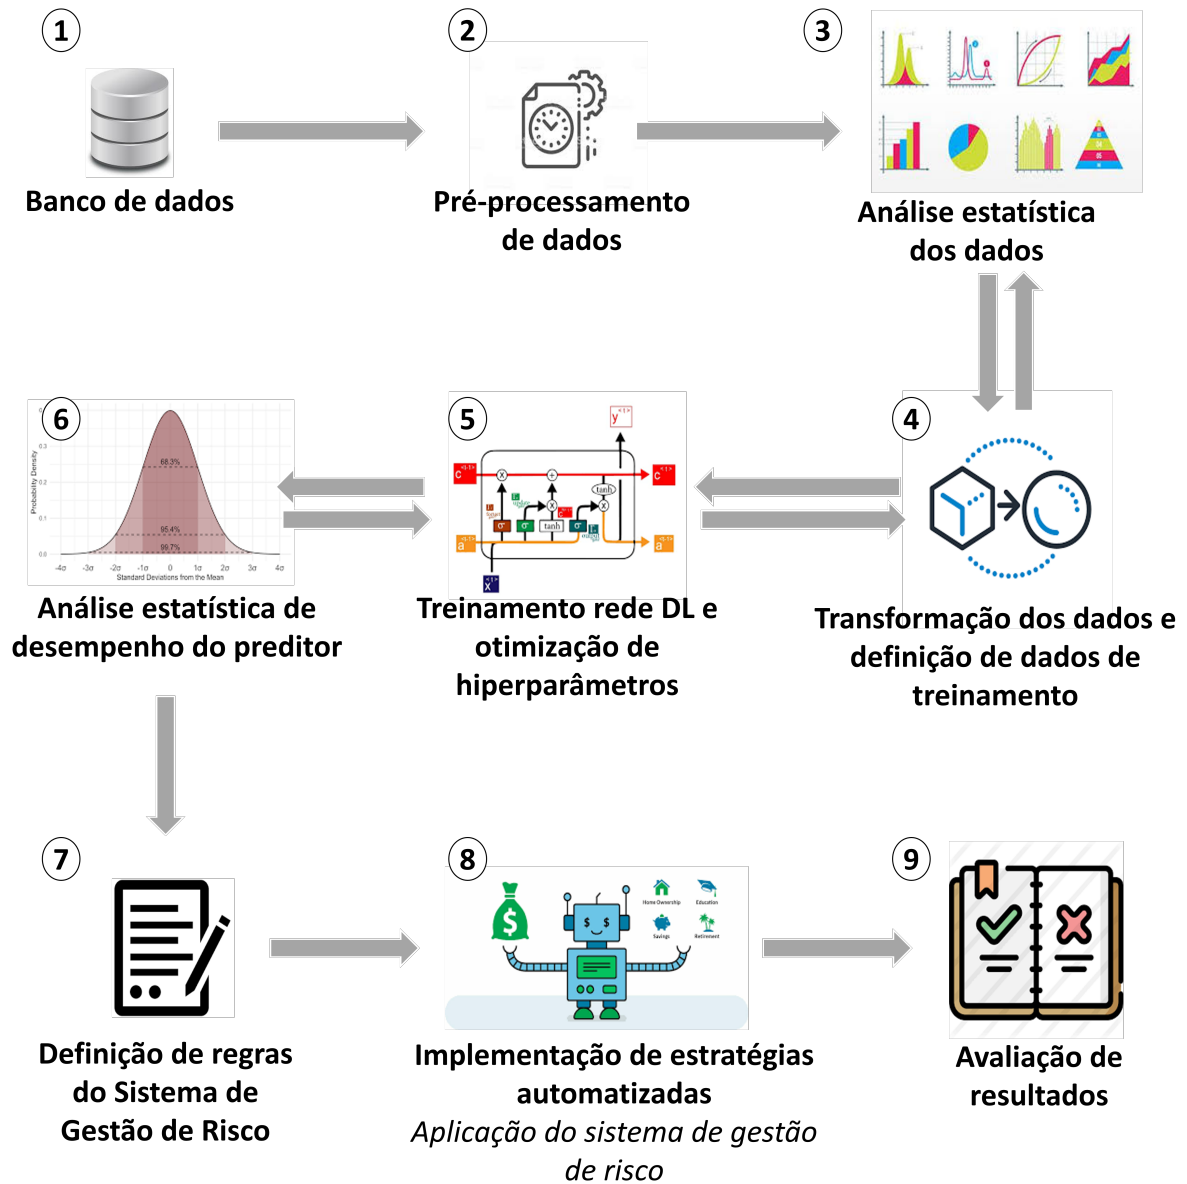
Na etapa 8 da metodologia (Seção 4.8) são apresentadas as estratégias automatizadas implementadas, detalhando as condições necessárias para sinalização de operações de compra, venda ou liquidação de posição.

Por fim, a última etapa da metodologia consistiu na realização de *backtesting* e análise de resultados (Seção 4.9).

É importante ressaltar que este trabalho foi desenvolvido em ciclos visando testar hipóteses e definir ajustes a fim de melhorar incrementalmente a solução no menor intervalo de tempo possível. Assim, embora o fluxo esteja representado de forma linear,

o desenvolvimento do trabalho exigiu diversas iterações entre as etapas, resultando em muitos dias de processamento computacional para o treinamento dos modelos de predição, bem como testagem de variações de dados de entrada para o treinamento dos modelos.

Figura 4.1: Figura demonstrativa das etapas metodológicas realizadas para o desenvolvimento do Sistema de Gestão de Risco (SGR) e avaliação de desempenho quando aplicado sobre estratégias automatizadas de negociação de ativos




Fonte: Elaborado pelo autor (2022)

4.1 Banco de dados

A coleta de dados representa a primeira etapa da metodologia. Foram obtidas as séries temporais de dados dos ativos pertencentes ao índice IBOVESPA entre janeiro/2008 e dezembro/2019 com a frequência de 15 minutos. Esses dados incluem os preços de abertura, máximo, mínimo, fechamento, volume em termos de quantidade de papéis negociados e volume financeiro negociado para cada intervalo de 15 minutos. Os dados relatados são conhecidos na literatura por *OHLCV* (*Open, High, Low, Close, Volume*).

Os dados OHLCV são geralmente analisados em gráficos de *candle* por profissionais do mercado financeiro. Eles são representados conforme a Figura 4.2, englobando um determinado período de tempo (*timeframe*), que pode variar de acordo com a necessidade. Em cada período de tempo, o *candle* apresenta os seguintes valores de um ativo: valor do primeiro negócio realizado (abertura), valor máximo e mínimo negociado, valor do último negócio realizado (fechamento). Além disso, o corpo do candle assume coloração distinta no caso de valorização ou depreciação do valor do ativo negociado no intervalo de tempo considerado. A informação de volume é geralmente apresentada em um gráfico secundário abaixo do gráfico de *candle*.

Figura 4.2: Figura exemplificativa da representação de preços no formato *Candlestick*



Fonte: [do Investidor \[2007\]](#)

Exemplificando uma série temporal, a Figura 4.3 apresenta o gráfico de *candles* diários do ativo PETR4 entre maio e julho de 2014, bem como o volume de negociação.

Para a execução dessa dissertação e devido ao elevado custo de processamento para o treinamento dos modelos LSTM e BiLSTM, foram selecionados 5 ativos para validar a aplicação do sistema de gestão de risco, são eles: ABEV3, B3SA3, ITUB4, PETR4 e USIM5. Esta seleção foi realizada devido ao fato de estarem entre os 10 ativos mais negociados no período dos dados e representarem setores econômicos diferentes.

Figura 4.3: Exemplo de gráfico de *Candles* com informação de volume negociado por meio de histograma - Ativo: PETR4



Fonte: Elaborado pelo autor (2022)

4.2 Pré-processamento de dados

Nesta etapa foram realizados testes para verificação da integridade dos dados, ajustando os dados nulos ou inválidos, e verificando possíveis inconsistências em relação aos preços das séries e volume de negociação.

Os dados originalmente coletados em intervalos de 15 minutos foram processados a fim de obter dados diários da seguinte forma:

- o valor de abertura do preço do ativo em determinado dia corresponde ao valor de abertura do primeiro *candle* daquele dia;
- o valor máximo de negociação do ativo no dia corresponde ao máximo dos valores máximos dos *candles* daquele dia;
- o valor mínimo de negociação do ativo no dia corresponde ao menor dos valores mínimo dos *candles* daquele dia;
- o valor de fechamento diário do ativo corresponde ao valor de fechamento do último *candle* do dia;
- o volume financeiro e em termos de quantidade de papéis corresponde ao somatório dos volumes negociados nos *candles* do dia.

Ao invés de utilizar o preço dos ativos em R\$, aplicou-se a função de log-retorno (r) sobre os dados, conforme equação 4.1, devido às propriedades estatísticas mais favoráveis ao treinamento dos modelos: distribuição normal, retorno acumulado pode ser obtido pelo somatório dos log-retornos e possui maior estabilidade numérica.

$$r_t = \ln \frac{P_t}{P_{t-1}} \quad (4.1)$$

onde:

- P_t : preço do ativo no instante t
- P_{t-1} : preço do ativo no instante anterior a t

Nesta etapa de processamento de dados também foram separados os dados a serem utilizados para treinamento/validação e *backtesting*. Os dados de treino/validação limitaram-se até a data de 28/02/2019, enquanto os dados de teste compreenderam o período de 02/04/2019 a 31/12/2019, no qual ocorreram situações diversas de mercado em alta, baixa e consolidação. O Apêndice C apresenta os gráficos das janelas de dados do *backtesting*.

Por fim, os dados de treino/validação foram normalizados pela média e desvio padrão, e em seguida transformados em uma escala de -1 a 1 a fim de evitar problemas de grandeza das diferentes variáveis de entrada no treinamento dos modelos.

4.3 Análise estatística dos dados

O terceiro passo metodológico, visando adquirir maior familiaridade com os dados, consistiu em realizar a análise estatística das séries temporais por meio de histogramas, testes de normalidade e análise de correlação cruzada das variáveis de log-retorno.

Primeiramente foram plotados dos gráficos de *boxplot* para adquirir conhecimento do intervalo de variação das variáveis de log-retorno. Em seguida, mapas de calor contribuíram para entender melhor a correlação cruzada dessas variáveis. Os gráficos de dispersão também contribuíram para visualização gráfica da correlação linear entre as variáveis e distribuição das mesmas. Testes de normalidade Shapiro-Wilk ([Shapiro and Wilk \[1965\]](#)) foram realizados para identificar se as variáveis eram amostras advindas de uma distribuição normal.

Por fim, foi realizada uma análise dos retornos percentuais entre valores máximos e mínimos de cotação do ativo em relação ao preço de abertura, bem como a distribuição da faixa de variação percentual entre o valor máximo e mínimo do ativo no mesmo dia.

Um segundo estudo também foi conduzido para calcular a probabilidade condicional de tendência diária do ativo de acordo com o preço de fechamento a cada hora em relação ao preço de abertura, conforme será apresentado na seção de Análise dos Resultados.

O Apêndice B apresenta as tabelas estatísticas e gráficos gerados no estudo das séries temporais dos 5 ativos utilizados nesse trabalho.

4.4 Transformação dos dados e definição de dados de treinamento

Embora haja trabalhos na literatura (Qiu et al. [2020]) nos quais são aplicadas transformações *wavelet* sobre os dados a fim de melhorar a relação sinal-ruído da série temporal, para este trabalho, optou-se por não realizar aplicação de filtros sobre os dados. No entanto, foram introduzidos indicadores técnicos aos dados de log-retorno que realizam média de dados passados. Os indicadores selecionados foram detectores de tendências representados pelos indicadores de média móvel, osciladores representados pelo RSI (Índice de força relativa), volatilidade (Canal de Keltner), volume de negociação (OBV) e preço do ativo ponderado pelo volume de negócios (VWAP).

Assim o processo de desenvolvimento dos preditores de valor máximo e mínimo diário dos ativos utilizou 4 (quatro) conjuntos de dados de entrada:

- Conjunto de variáveis de log-retorno - OHLCV (Total de 9 variáveis de entrada)
- Conjunto de variáveis de log-retorno - OHLCV + Variáveis adicionais calculadas como relações das variáveis de preço dos ativos - Variáveis adicionais (Total de 21 variáveis de entrada)
- Conjunto de variáveis de log-retorno - OHLCV + Indicadores técnicos (Total de 24 variáveis de entrada)
- Conjunto de variáveis de log-retorno - OHLCV + Variáveis adicionais calculadas como relações das variáveis de preço dos ativos - Variáveis adicionais + Indicadores técnicos (Total de 36 variáveis de entrada)

A Tabela 4.1 apresenta a descrição de todas as variáveis de entrada utilizadas para o treinamento das redes recorrentes na etapa seguinte. É importante ressaltar que foi aplicada a função de log retorno sobre os indicadores técnicos, com excessão do indicador OBV no qual foi aplicada a diferença em relação ao período anterior, antes do processo de normalização e escala dessas variáveis.

Tabela 4.1: Definição das variáveis de entrada e dos diferentes conjuntos de dados de entrada para treinamento dos modelos

Conjunto de entrada	Variável	Descrição
OHLCV (9 variáveis)	$L_{o,c}$	Log do preço de abertura do dia t em relação ao preço de fechamento em t-1
	$L_{h,c}$	Log do preço máximo do dia t em relação ao preço de fechamento em t-1
	$L_{l,c}$	Log do preço mínimo do dia t em relação ao preço de fechamento em t-1
	L_c	Log do preço de fechamento do dia t em relação ao preço de fechamento em t-1
	L_q	Log da quantidade de ações negociadas no dia t em relação à quantidade de ações negociadas no dia t-1
	L_o	Log do preço de abertura do dia t em relação ao preço de abertura em t-1
	L_h	Log do preço máximo do dia t em relação ao preço máximo em t-1
	L_l	Log do preço mínimo do dia t em relação ao preço mínimo em t-1
	L_g	Log do preço de abertura do dia t+1 em relação ao preço de fechamento em t
Variáveis calculadas adicionais (12 variáveis)	R_{abs}	Variação em termos absolutos do preço máximo e mínimo no dia t
	L_{Rabs}	Log de $(\text{Preço máximo}_{(t)} - \text{Preço mínimo}_{(t)}) / (\text{Preço máximo}_{(t-1)} - \text{Preço mínimo}_{(t-1)})$
	$Gap\%$	$100 * [\text{Preço abertura}_{(t)} - \text{Preço fechamento}_{(t-1)}] / \text{Preço fechamento}_{(t-1)}$
	R_c	$100 * \text{Preço fechamento}_{(t)} / \text{Preço fechamento}_{(t-1)}$
	R_h	$100 * \text{Preço máximo}_{(t)} / \text{Preço fechamento}_{(t-1)}$
	R_l	$100 * \text{Preço mínimo}_{(t)} / \text{Preço fechamento}_{(t-1)}$
	R_o	$100 * \text{Preço fechamento}_{(t)} / \text{Preço abertura}_{(t)}$
	$High_o$	$100 * [\text{Max}(t) - \text{Abertura}(t)] / \text{Abertura}(t)$
	$High_c$	$100 * [\text{Max}(t) - \text{Fechamento}(t)] / \text{Fechamento}(t)$
	Low_o	$100 * [\text{Min}(t) - \text{Abertura}(t)] / \text{Abertura}(t)$
	Low_c	$100 * [\text{Min}(t) - \text{Fechamento}(t)] / \text{Fechamento}(t)$
	D_w	Variável categórica representando o dia da semana (seg/ter/qua/quí/sex)
Indicadores Técnicos* (15 variáveis)	SMA_c	3 médias móveis aritméticas: 5, 10 e 20 períodos do Preço de fechamento
	SMA_h	3 médias móveis aritméticas: 5, 10 e 20 períodos do Preço máximo
	SMA_l	3 médias móveis aritméticas: 5, 10 e 20 períodos do Preço mínimo
	RSI	Indicador de força relativa calculado sobre os últimos 12 períodos
	KC_l	$KC_b - 2$ desvios-padrão
	KC_b	Base do Canal de Keltner: média móvel exponencial do preço de fechamento dos últimos 12 períodos
	KC_u	$KC_b + 2$ desvios-padrão
	OBV	Indicador On Balance Volume
VWAP	Preço médio ponderado pelo volume nos últimos 12 períodos	

Fonte: Elaborada pelo autor (2022)

4.5 Treinamento das redes neurais LSTM e BiLSTM

Esta etapa consistiu no treinamento de modelos LSTM e BiLSTM para realizar a predição do preço máximo e mínimo do ativo no dia atual (2 saídas), com base nos dados disponíveis até o preço de abertura do dia.

Foram utilizados 4 conjuntos de dados de entrada para treinamento dos modelos, conforme descrito na Seção 4.4 deste capítulo. A métrica utilizada para comparar os

modelos foi o erro quadrático médio (RMSE) e para cada conjunto de dados de entrada foram treinados 1800 modelos por meio da técnica de *Grid search*, devido a combinação de parâmetros estruturais apresentada na Tabela 4.2.

Tabela 4.2: Parametrização da estrutura dos modelos a serem otimizados pela técnica *Grid search*

Aspecto	Opções	Quantidade de possibilidades
Tipo do modelo	LSTM ou BiLSTM	2
Mecanismo de atenção	Com ou sem mecanismo de atenção	2
Tamanho da janela	De 1 a 30 períodos anteriores ao dia atual	30
Quantidade de camadas	De 1 a 3 camadas	3
Quantidade de células de memória por camada	Fatores (1,2,3,5 e 10) em relação ao tamanho da janela	5
Quantidade total de modelos treinados para cada conjunto de dados de entrada		1800

Fonte: Elaborada pelo autor (2022)

Segundo [Trevor Hastie \[2009\]](#), em situações nas quais há dados abundantes, a melhor abordagem é separar aleatoriamente os dados em três partes: dados de treino, dados de validação e dados de teste. Os dados de treino são utilizados para otimização dos modelos, enquanto os dados de validação são usados para estimar o erro de predição do modelo selecionado. Os dados de teste são utilizados para avaliação da generalização do modelo selecionado. Apesar de ser difícil estabelecer uma regra geral, devido ao tamanho de cada conjunto de dados depender da relação sinal-ruído dos dados e do tamanho dos dados de treino, o autor sugere uma divisão de 50%, 25% e 25% para os dados de treino, validação e teste.

Para o treinamento dos modelos dessa dissertação, de forma a permitir o treinamento dos modelos em diferentes situações de mercado e devido ao fato das séries temporais de preço apresentarem ruído considerável ([Israel et al. \[2020\]](#)), foram utilizados 70% dos dados restantes para treino, 15% para validação e 15% para teste. O treinamento dos modelos iniciou-se sempre com a mesma semente de número aleatório, bem como os mesmos dados de treinamento e validação.

O algoritmo de otimização utilizado no treino foi o *adam* (*adaptive moment estimation*). O treinamento foi limitado a quantidade máxima de 500 épocas e utilizando o mecanismo de *early stopping* com parâmetro de paciência igual a 25 épocas. Isto significa que o modelo selecionado será aquele que apresentou o menor valor de RMSE durante o treinamento e que não foi superado nas próximas 25 épocas.

A Tabela 4.3 apresenta a sequência de ciclos de desenvolvimento aplicada visando obter o melhor preditor para os valores de máximo e mínimo dos 5 ativos utilizados nessa dissertação (PETR4, ITUB4, USIM5, B3SA3 e ABEV3). Ressalta-se que a otimização de estrutura dos modelos exigiu muito esforço computacional, haja vista que o treinamento de cada modelo variou entre 2 a 4 minutos, totalizando média de 90 horas para obtenção de um modelo otimizado para cada ativo e conjunto de dados de entrada.

Tabela 4.3: Esforço estimado no processo de otimização da estrutura dos modelos de predição baseado na técnica *Grid search*

Ciclo	Descrição	Dados de entrada	Quantidade de modelos treinados	Tempo médio para treinamento do ciclo (dias)
1º	Modelo de predição de valor Máximo e Mínimo, utilizando apenas dados de log-retorno como entrada	Variáveis de log-retorno OHLCV (9 variáveis)	5*1800 = 9.000	18,75
2º	Modelo de predição de valor Máximo e Mínimo, utilizando dados de log-retorno e variáveis calculadas como entrada	Variáveis de log-retorno OHLCV + Variáveis calculadas (21 variáveis)	5*1800 = 9.000	18,75
3º	Modelo de predição de valor Máximo e Mínimo, utilizando dados de log-retorno e indicadores técnicos como entrada	Variáveis de log-retorno OHLCV + Indicadores técnicos (24 variáveis)	5*1800 = 9.000	18,75
4º	Modelo de predição de valor Máximo e Mínimo, utilizando todas as variáveis de entrada dos ciclos anteriores	Variáveis de log-retorno OHLCV + Variáveis calculadas + Indicadores técnicos (36 variáveis)	5*1800 = 9.000	18,75
Quantidade total de modelos treinados			36.000	75 dias

Fonte: Elaborada pelo autor (2022)

Ressalta-se o grande esforço computacional empregado nesta etapa do trabalho que necessitou de 75 dias de computação (sem uso de computação paralela) para obtenção de dados a serem avaliados na etapa posterior de análise estatística de desempenho dos modelos.

Após a execução dos treinamentos dos modelos, selecionou-se os 5 modelos para cada conjunto de dados de entrada com os melhores valores de RMSE para cada ativo. Em seguida, treinou-se 10 vezes cada um desses modelos utilizando diferentes combinações de conjuntos de dados de treino e validação por meio da aleatorização da semente de seleção dos dados. Ao final, foi selecionado o modelo de predição que apresentou a menor média de RMSE para ser utilizado no sistema de gestão de risco do ativo.

4.6 Análise estatística do desempenho dos modelos

Nesta etapa do trabalho buscou-se analisar estatisticamente o resultado do treinamento dos diversos modelos e estruturas da etapa anterior, de forma a entender a influência das configurações do modelo na métrica RMSE. Foram realizados as análises e testes estatísticos não paramétricos:

- Teste de normalidade *Shapiro-Wilk* ([Shapiro and Wilk \[1965\]](#)) sobre a distribuição de valores RMSE dos modelos treinados para cada conjunto de dados de entrada;
- Teste não pareado *Mann-Whitney* ([Mann and Whitney \[1947\]](#)) para determinar

qual conjunto de dados de entrada resulta em modelos com melhor distribuição de RMSE;

- Teste pareado *Wilcoxon Signed-Rank* (Wilcoxon [1992]) para determinar qual arquitetura de rede recorrente resulta em modelos com melhor distribuição de RMSE (LSTM ou BiLSTM);
- Teste pareado *Wilcoxon Signed-Rank* para determinar se mecanismo de atenção resulta em modelos com melhor distribuição de RMSE;
- Análise do impacto dos parâmetros na métrica RMSE obtida no treinamento dos modelos: tamanho da janela, quantidade de camadas, quantidade de células de memória por camada;

Os resultados das análises realizadas são de grande valia para entender como reduzir o esforço em treinamento caso seja desejável aplicar a mesma metodologia para predição de outros ativos, pois reduz o universo de possibilidades de parâmetros para um conjunto mais provável de se obter o modelo ótimo.

Por fim, também foi realizado o sumário estatístico do erro de predição dos valores máximo e mínimo do ativo com o preditor selecionado para o sistema de gestão de risco (SGR).

4.7 Definição de regras do sistema de gestão de risco (SGR)

Nessa etapa da metodologia foram estabelecidas as regras e funcionamento do sistema de gestão de risco (SGR) de risco para ser aplicado sobre qualquer estratégia de operação subjacente, baseando-se nos valores previstos pelos modelos e a distribuição de erros de predição. A Figura 4.4 apresenta o pseudocódigo do sistema de gestão de risco.

O Sistema de gestão de risco recebe como entradas as cotações diárias dos últimos d dias, o preço de abertura do dia, e as distribuições de erro do preditor nos dados de validação, para que possa realizar a predição dos valores máximo e mínimo do dia, de acordo com o modelo otimizado para cada ativo.

Pelo pseudocódigo verifica-se que, a princípio, o SGR está disponível para operar todos os dias. Às 10 horas é realizada a predição dos valores mínimos e máximo e essa predição é comparada com o preço de abertura do ativo. Caso haja alguma inconsistência do valor máximo previsto ser menor que o preço de abertura ou o valor mínimo ser maior

Figura 4.4: Detalhamento do algoritmo do Sistema de Gestão de Risco (SGR)

Algoritmo: Sistema de Gestão de Risco**Entrada:** Dados OHLCV, Preditor, DistribuicaoErros

```

1:  $n \leftarrow 1$ 
2: enquanto  $n \leq$  último dia Backtesting faça
3:   SGR.disponível  $\leftarrow 1$ 
   # Realiza a previsão do limite diário na abertura e realiza ajustes, se necessário
4:   se hora = 10:00 então
5:      $MAX_p, MIN_p \leftarrow$  Preditor.preverLimiteDiário(OHLCV(n-d),  $O_n$ )
6:     se  $MAX_p \leq O_n$  ou  $(MAX_p \geq O_n$  e  $(MAX_p - O_n) \leq atr_n)$  então
7:        $MAX_p \leftarrow$  SGR.ajustaPelaDistribGeral( $MAX_p$ )
8:     fim se
9:     se  $MIN_p \geq O_n$  ou  $(MIN_p \leq O_n$  e  $(O_n - MIN_p) \leq atr_n)$  então
10:       $MIN_p \leftarrow$  SGR.ajustaPelaDistribGeral( $MIN_p$ )
11:    fim se
12:    se  $MIN_p \leq O_n$  e  $MAX_p \geq O_n$  então
13:      regiãoCompra  $\leftarrow [0..MIN_p]$ ; regiãoVenda  $\leftarrow [MAX_p..inf]$ ;
14:    senão
15:      SGR.disponível  $\leftarrow 0$ 
16:    fim se
17:  fim se
18:  enquanto Pregão estiver aberto faça:
19:    se hora for [11:00, 12:00, 13:00, 14:00, 15:00, 16:00] então
20:      se Tendência Diário for de alta então
21:         $MAX_p, MIN_p \leftarrow$  SGR.ajustaPelaDistribAlta( $MAX_p, MIN_p$ )
22:      senão
23:         $MAX_p, MIN_p \leftarrow$  SGR.ajustaPelaDistribBaixa( $MAX_p, MIN_p$ )
24:      fim se
25:      regiãoCompra  $\leftarrow [0..MIN_p]$ ; regiãoVenda  $\leftarrow [MAX_p..inf]$ ;
26:    fim se
27:  fim enquanto

```

Fonte: Elaborado pelo autor (2022)

que o preço de abertura, o SGR realiza o ajuste da predição baseada na distribuição de erros de predição do modelo nos dados de validação. Tal ajuste consiste em multiplicar a predição pelo percentil 50% da distribuição de erro. Nota-se que as predições também são ajustadas caso a diferença entre o valor previsto e o preço de abertura seja menor que uma unidade de *atr* (*average true range*). O valor de *atr* consiste na média do intervalo de variação dos *candles* de 15 minutos nos 5 dias anteriores ao dia em questão. Por fim, caso após os ajustes não haja inconsistência na predição em relação ao preço de abertura, são definidas as regiões de compra e venda permitidas pelo SGR. Caso haja inconsistências (linha 12), o sistema de gestão de risco não será considerado disponível para o dia e nenhuma operação que abra posição será permitida. Neste caso, apenas as operações que encerram posições serão permitidas.

Ao longo do dia, após o fechamento de cada hora, verifica-se a tendência diária do ativo. Caso o preço de fechamento da hora seja maior que o preço de abertura, a tendência é de alta, caso contrário de baixa. Realiza-se então o ajuste das predições de acordo com a distribuição de erro de predição para a tendência e recalcula-se as regiões de compra e venda.

O ajuste das predições de acordo com a tendência é realizado para que mitigue-se a chance de criar posições de compra em dias de baixa e posições de venda em dias de alta. Assim, caso o dia seja de alta, o valor máximo previsto será ajustado de acordo com o erro do percentil 20% da distribuição de erros do valor máximo nos dias de alta, e o valor mínimo previsto será ajustado de acordo com o erro do percentil 80% da distribuição de erros do valor mínimo nos dias de alta. Ajuste análogo ocorre no caso de dias com tendência de baixa.

Outros aspectos considerados pelo SGR são listados a seguir:

- **Horário permitido para operações:** definiu-se que o SGR irá permitir abertura de posições apenas após 11 horas, devido ao fato de nesse momento haver uma tendência mais clara do preço do ativo para que haja os ajustes necessários nas predições do modelo. Antes de 11 horas, o SGR permite a zeragem de posições pelas estratégias;
- **Nível de exposição por operação baseada no critério de Kelly:** o tamanho da posição permitida pelo SGR equivale a $1/3$ do valor de Kelly obtido pela estratégia nos dados de validação;
- **Reversão de posições:** o SGR apenas permite reversão de posição, caso o sinal dado pela estratégia esteja na região adequada, caso contrário, o SGR permite apenas a zeragem da posição. Por exemplo, caso a estratégia esteja comprada em X unidades do ativo e emita um sinal de reversão para ficar em posição vendida, o SGR irá permitir a venda de $2X$ unidades apenas se o preço do ativo estiver na região de venda, caso contrário, irá permitir a venda de X unidades, de forma a zerar a posição.
- **Especificação e dimensionamento de *stoploss*:** o SGR utilizará *stoploss* equivalente a $1/3$ do percentil 50% da distribuição de retorno percentual entre o valor máximo e mínimo. Essa definição visa estabelecer um critério de *stop* condizente com o nível de variação histórico de cada ativo.
- **Definição de modo de conduta para alvo das operações (*take profit*):** definiu-se que as posições serão encerradas conforme sinais de compra/venda das estratégias nas quais aplicou-se o SGR.

4.8 Implementação de estratégias automatizadas

Foram implementadas 7 (sete) estratégias de operação automatizada, sendo 2 (duas) com base nas estruturas otimizadas de LSTM/BiLSTM encontradas na dissertação e 5 (cinco) baseadas em estratégias bastante populares no mercado financeiro envolvendo utilização de indicadores técnicos para rastreamento de tendências (*trend follower*) e osciladores (identificação de momento e divergências).

As estratégias baseadas em indicadores técnicos tiveram seus parâmetros otimizados para cada ativo nos dados de treino. Para essa otimização, as estratégias foram aplicadas nos dados de treino dos ativos de forma livre (sem uso de *stoploss* e tamanho de posição fixo em 10 % do capital (capital inicial de R\$ 100 mil). Assim, as entradas e saídas das operações foram realizadas apenas pelos gatilhos da própria estratégia. Utilizando a técnica de *Grid search*, obteve-se a taxa de acerto global (considerando operações de compra e venda) e a relação risco/ganho para cada configuração possível de parâmetros da estratégia.

Visando maximizar o tamanho da posição de cada operação por meio do critério de Kelly, o qual considera a taxa de acerto e relação de risco/ganho. Quando o valor calculado pelo critério de Kelly é menor ou igual a zero, utilizou-se a configuração de parâmetros com maior taxa de acerto e em caso de empate, a maior relação de risco/ganho no âmbito geral das operações realizadas (compra e venda). Também foi adotado um critério restritivo de haver ao menos uma quantidade de operações igual a 1/8 da quantidade de dias dos dados de treino.

Já as duas estratégias baseadas nos preditores encontrados na dissertação podem ser consideradas otimizadas para cada ativo, devido ao processo realizado para obtenção dos modelos.

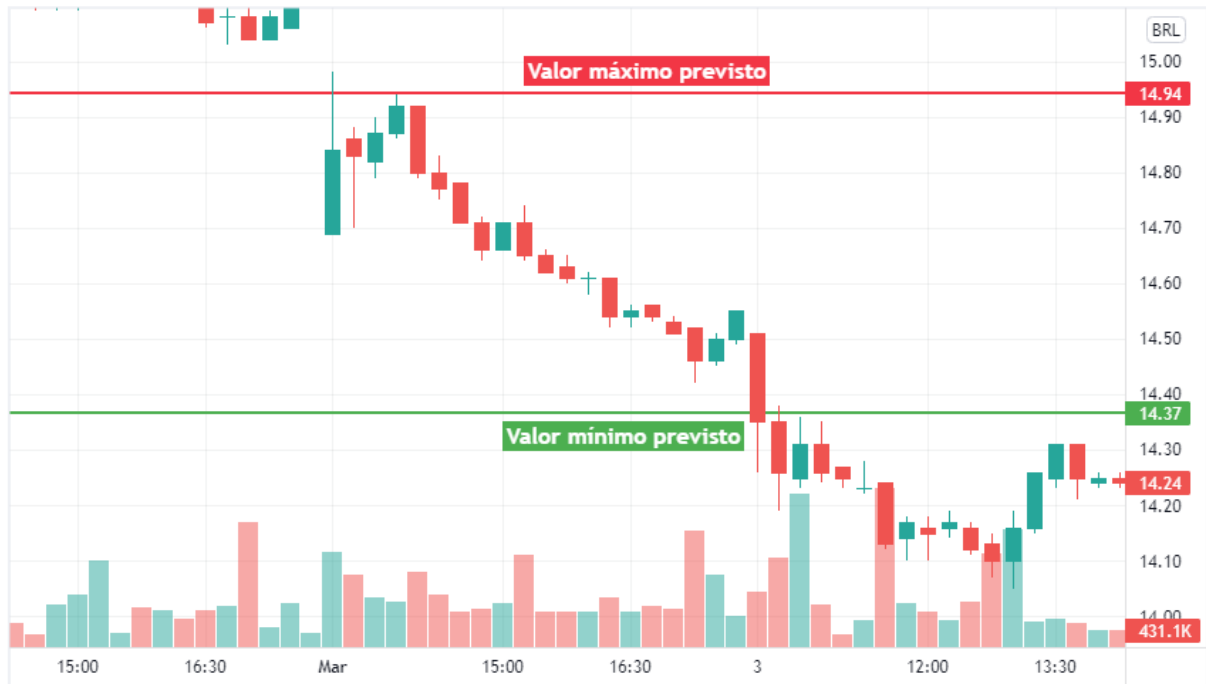
A seguir são apresentadas as estratégias implementadas, quais os parâmetros configuráveis e os gatilhos de entrada e saída de operação de cada estratégia.

4.8.1 Estratégia Buy low/Sell High

A estratégia denominada nessa dissertação como *Buy low/Sell high* consiste basicamente em iniciar operações de compra em uma região no entorno da previsão de valor mínimo do ativo e iniciar operações de venda no entorno da previsão de valor máximo do ativo (1 atr). A previsão de preço máximo e mínimo do ativo para determinado dia é fornecida pelo modelo selecionado para o ativo.

A Figura 4.5 exemplifica a estratégia *Buy low/Sell high*. A estratégia permite realizar apenas uma operação por dia. Caso seja aberta uma posição de compra em determinado dia, mas o valor máximo previsto não seja atingido e a operação esteja em situação de lucro, a posição é mantida aberta para o próximo pregão, caso contrário, a posição é encerrada no preço de fechamento do *candle* de 17:00.

Figura 4.5: Exemplo da aplicação da estratégia *Buy low/Sell high* para negociação do ativo ABEV3. Dados do dia 02/03/2022



Fonte: Elaborado pelo autor no site www.tradingview.com (2022)

4.8.2 Estratégia *Act on opening*

A estratégia denominada nessa dissertação como *Act on opening* consiste em utilizar um classificador de tendência, treinado utilizando rede LSTM com o mesmo conjunto de dados de entrada dos preditores selecionados para cada ativo, no entanto, realizando a otimização da janela temporal, quantidade camadas e células LSTM por camada, a fim de prever se a tendência no dia será de alta (preço de fechamento \geq preço de abertura) ou de não-alta (preço de fechamento $<$ preço de abertura).

Baseado na previsão de tendência, será iniciada uma ordem de compra ou venda no preço de encerramento do primeiro *candle* do dia e esta posição será finalizada no final

do mesmo dia. Assim, todas as operações dessa estratégia ocorrerão dentro do mesmo dia e apenas uma por dia. A Figura 4.6 exemplifica a estratégia *Act on opening*.

Figura 4.6: Exemplo da estratégia *Act on opening* aplicada ao ativo ABEV3. Dados do dia 01/03/2022



Fonte: Elaborado pelo autor no site www.tradingview.com (2022)

4.8.3 Cruzamento de média (*Crossover*)

A estratégia de cruzamento de média visa rastrear tendência do ativo, seja de alta ou de baixa, e utiliza uma média móvel do preço de fechamento do ativo nos últimos n períodos. Para esta estratégia foi utilizada a média simples. Em relação à quantidade de períodos a ser utilizada pela média, este valor foi otimizado para cada ativo a ser operado.

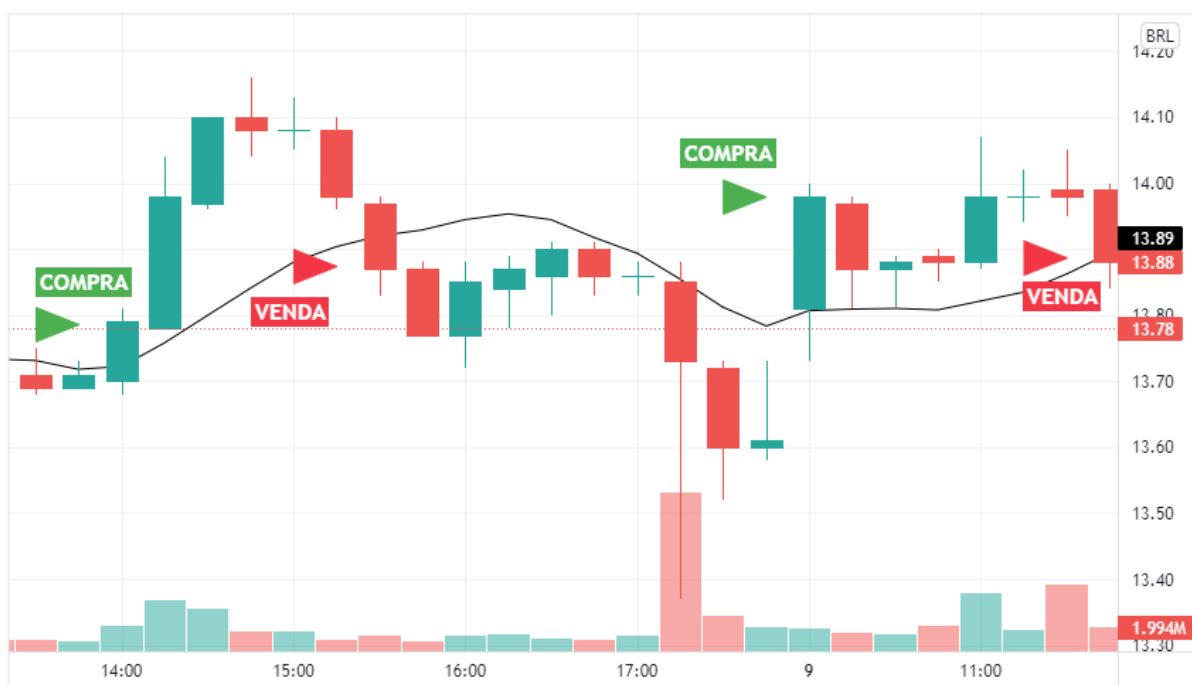
O sinal de compra dessa estratégia ocorre sempre que a linha de preços de fechamento cruzar para cima a média móvel, sinalizando o início de um movimento de alta. Já o sinal de venda da estratégia ocorre sempre que a linha de preços de fechamento cruzar para baixo a média móvel, sinalizando o início de um movimento de baixa. Uma vez iniciada, a estratégia irá alternar a posição entre compra e venda sempre que houver os cruzamentos citados anteriormente.

A estratégia de cruzamento de média geralmente cria muitos sinais de operações, a depender do *timeframe* utilizado e da volatilidade de preço do ativo, o que pode gerar

muitos sinais falsos de início de movimento, minando a lucratividade da estratégia quando considerados os custos de transação.

A Figura 4.7 apresenta operações indicadas pela estratégia de cruzamento de média. Observa-se nesse caso, que devido à média levar mais tempo para acompanhar o movimento de alta da primeira operação, o lucro auferido foi pequeno em relação ao topo atingido pelo preço antes de cruzar a média novamente e iniciando uma posição de venda, a qual foi encerrada devido ao *gap* de abertura do dia seguinte de negociação, levando neste caso a um prejuízo.

Figura 4.7: Exemplo da estratégia de negociação baseada no cruzamento de média simples de 9 períodos com preço de fechamento do *candle* aplicada ao ativo B3SA3. Dados dos dias 08 e 09/03/2022



Fonte: Elaborado pelo autor no site www.tradingview.com (2022)

4.8.4 Cruzamento de duas médias móveis (*Double crossover*)

O conceito por trás da estratégia de cruzamento de duas médias móveis é criar um sistema oscilador que permita identificar melhor a tendência de movimento do ativo com menor atraso possível e reduzir a quantidade de sinais falsos em relação à estratégia de cruzamento de uma única média móvel.

Para esta estratégia são utilizadas duas médias móveis, onde uma é denominada média rápida, pois realiza média sobre um número menor de períodos do que a segunda média, a média lenta. Da mesma forma que a estratégia de cruzamento de uma média, a quantidade de períodos das médias pode ser otimizada para cada ativo a ser operado.

O sinal de compra dessa estratégia ocorre sempre que a média rápida cruzar para cima a média lenta, sinalizando o início de um movimento de alta. Já o sinal de venda da estratégia ocorre sempre que a média rápida cruzar para baixo a média lenta, sinalizando o início de um movimento de baixa. Uma vez iniciada, a estratégia irá alternar a posição entre compra e venda sempre que houver os cruzamentos citados anteriormente.

A estratégia de cruzamento de duas médias tende a gerar menos operações que a estratégia utilizando apenas uma média móvel. Isto deve-se à característica de suavização da média móvel, que reduz a quantidade de ruído da série de preço de fechamento do ativo.

A Figura 4.8 apresenta operações indicadas pela estratégia de cruzamento de duas médias.

Figura 4.8: Exemplo da estratégia Cruzamento de duas médias (média simples de 4 e 9 períodos) aplicada ao ativo B3SA3 nos dias 07 e 08/03/2022



Fonte: Elaborado pelo autor no site www.tradingview.com (2022)

4.8.5 Cruzamento de três médias móveis (*Triple crossover*)

A estratégia de Cruzamento de três médias móveis consiste em um sistema oscilador que visa reduzir a quantidade de sinais falsos em relação à estratégia de cruzamento de duas médias móveis e rastrear movimentos mais longos de tendência.

Para esta estratégia são utilizadas três médias móveis, onde uma é denominada média lenta, pois realiza média sobre um número maior de períodos, a segunda média é denominada média intermediária, e a terceira média rápida, pois rastreia um número menor de períodos e, portanto, responde mais prontamente à movimento nos preços. Da mesma forma que as estratégias anteriores de cruzamento de, a quantidade de períodos das médias pode ser otimizada para cada ativo a ser operado.

Existem duas formas de interpretar os sinais de compra e venda da estratégia. Na primeira variação da estratégia, há a possibilidade de liquidar a posição no ativo e aguardar um novo momento para iniciar um posicionamento de compra/venda. Na segunda variação, a posição no ativo fica alternada, ora comprado, ora vendido, como ocorre nas estratégias de cruzamento de uma média e de duas médias.

O sinal de entrada, tanto de compra como de venda é o mesmo nas duas variações. Sempre que a média rápida estiver acima das duas outras médias, e houver o cruzamento para cima da média intermediária em relação à média lenta, há a indicação de uma operação de compra. Situação inversa ocorre para iniciar uma posição de venda. Para isto, a média rápida deve estar abaixo das duas outras médias e a média intermediária deve cruzar para baixo a média lenta.

Após iniciar uma operação de compra, a primeira variação da estratégia permite liquidar essa posição quando houver o cruzamento da média rápida para abaixo da média intermediária, sinalizando um possível enfraquecimento do movimento de alta. A partir daí, pode haver um momento sem posicionamento no ativo, até que se confirme uma reversão de movimento e a estratégia indique uma operação de venda. Situação análoga ocorre para liquidar uma posição de venda, quando o movimento de baixa enfraquecer e for sinalizado pelo cruzamento da média rápida para acima da média intermediária. A Figura 4.9 exemplifica os sinais de compra/venda da primeira variação da estratégia de cruzamento de três médias, a qual permite não haver posicionamento no ativo. Observe-se que a posição de compra é liquidada e apenas após alguns *candles* é que se inicia um posicionamento de venda no ativo, sendo esta posição também liquidada após um movimento de baixa seguido de uma pequena alta no preço do ativo.

Na segunda variação da estratégia, uma vez iniciada, haverá uma alternância de posicionamento no ativo de acordo com os sinais descritos anteriormente. No entanto, sempre haverá um posicionamento no ativo em qualquer instante de tempo, conforme demonstrado na Figura 4.10.

Figura 4.9: Exemplo da estratégia de negociação baseada no cruzamento de três médias simples de 4, 9 e 18 períodos aplicada ao ativo B3SA3. Esta variação da estratégia permite liquidar posição. Dados dos dias 03 e 04/03/2022



Fonte: Elaborado pelo autor no site www.tradingview.com (2022)

Figura 4.10: Exemplo da estratégia de negociação baseada no cruzamento de três médias simples de 4, 9 e 18 períodos aplicada ao ativo B3SA3. Dados dos dias 03 e 04/03/2022. Esta variação permite apenas a reversão de posição, mantendo sempre alocação de 100% no ativo.



Fonte: Elaborado pelo autor no site www.tradingview.com (2022)

4.8.6 Estratégia baseada em RSI (*Relative Strength Index*)

A estratégia baseada em RSI (indicador apresentado na seção 3.3.2 deste documento), em termos de sinais de compra e venda, pode ser interpretada da seguinte forma: uma vez na região de sobrevenda (RSI abaixo do limite inferior) e havendo o cruzamento para cima desse limite, a estratégia indica uma operação de compra do ativo. De forma análoga, estando na região de sobrecompra (RSI acima do limite superior) e havendo o cruzamento para abaixo desse valor, uma operação de venda pode ser iniciada ou uma posição comprada já existente invertida para venda.

A estratégia implementada mantém posição aberta no ativo a todo instante e os gatilhos de cruzamento dos valores de limite superior e inferior geram a inversão da posição no ativo.

É possível otimizar a estratégia baseada em RSI para determinado ativo por meio de três parâmetros: a quantidade de períodos da janela de dados, o valor limite inferior e o valor do limite superior para sinalização de operações.

A Figura 4.11 apresenta um exemplo de dois sinais de operação da estratégia baseada em RSI. O primeiro é uma venda ocorrida após o cruzamento para baixo do limite superior de 70%, e o segundo sinal é a inversão da posição de venda para compra, quando a linha de RSI adentrou sutilmente a região de sobrevenda (abaixo de 30%) e houve o cruzamento para cima desse limite inferior.

4.8.7 Estratégia baseada em MACD (*Moving Average Convergence -Divergence*)

A estratégia baseada no indicador MACD, apresentado na Seção 3.3.3 deste documento, realiza a abertura de uma posição de venda quando, estando em região de sobrecompra, há o cruzamento do histograma para valores negativos, enquanto o cruzamento do histograma para valores positivos, estando anteriormente em região de sobrevenda, sugere a abertura de uma posição de compra.

Caso os cruzamentos do histograma não sejam realizados com o MACD nas regiões de sobrecompra/sobrevenda, pode-se utilizar esse sinal para liquidar posições existentes. Desta forma, a estratégia baseada em MACD possui duas variações, a primeira permite momentos em que não há posição no ativo, e a segunda atua apenas invertendo a posição de compra para venda e vice-versa.

Figura 4.11: Exemplo da estratégia de negociação baseada em RSI aplicada ao ativo USIM5



Fonte: Elaborado pelo autor no site www.tradingview.com (2022)

A Figura 4.12 apresenta a variação da estratégia baseada em MACD que permite a liquidação da posição e, portanto, momentos sem posição no ativo. Observa-se que o cruzamento do histograma para valores positivos em região de sobrevenda ensejou a abertura de uma posição comprada a qual foi liquidada posteriormente quando houve o cruzamento do histograma para valores negativos em região de sobrevenda. Em seguida, houve um tempo sem posição até que iniciou-se uma série de operações de compra e venda não lucrativas devido à consolidação do preço do ativo.

A Figura 4.13 apresenta a variação da estratégia baseada em MACD que realiza a alternância de posição no ativo. Observa-se um número menor de operações, sendo o primeiro *trade* coincidente com a primeira variação da estratégia. No entanto, a ordem de venda realiza a inversão de posição e a ordem posterior de compra garante uma operação lucrativa. Após a inversão para posição comprada, a estratégia não gera novos sinais de operação durante a consolidação de preço do ativo.

Por fim, a otimização da estratégia baseada em MACD para cada ativo ocorre pela seleção da quantidade adequada de períodos das médias móveis do indicador MACD (3 médias).

Figura 4.12: Exemplo da estratégia baseada em MACD com liquidação de posição aplicada ao ativo ABEV3



Fonte: Elaborado pelo autor no site www.tradingview.com (2022)

4.9 *Backtesting* e Análise de resultados

Para realização do *backtesting* foi utilizado o **Backtrader**, um *framework* de código aberto baseado em Python, o qual já possui uma infraestrutura pronta para testar estratégias de *trading*.

Inicialmente, foi definido o intervalo de dados a ser utilizado nos cenários de teste, o qual correspondeu a janela temporal de 02/abril/2019 a 31/dezembro/2019, sendo que estes dados em momento algum foram utilizados nas etapas anteriores da metodologia. Considerou-se um capital inicial de R\$ 100 mil e custo de transação de 0,03% (referente a custos de liquidação e negociação da B3, B3 [2022]) sobre o valor financeiro operado. Não foram consideradas taxas fixas de corretagem, uma vez que algumas corretoras não tem mais aplicado esse tipo de taxa sobre as transações de ações.

Em seguida, é necessário gerar um *baseline* para comparar os resultados a serem obtidos no trabalho. Esse *baseline* possui duas dimensões, sendo o *baseline* primário o retorno financeiro obtido por um investidor no cenário de teste, utilizando a estratégia de comprar o ativo no primeiro dia e vendê-lo no último dia (*buy and hold*). Devido ao fato de as estratégias não utilizarem 100% do capital disponível, foram calculados os retornos da estratégia *buy and hold* utilizando 2%, 5%, 10%, 20% e 30% do capital. Não

Figura 4.13: Exemplo da estratégia baseada em MACD aplicada ao ativo ABEV3. Esta variação permite apenas a reversão de posição, mantendo sempre alocação de 100% no ativo.



Fonte: Elaborado pelo autor no site www.tradingview.com (2022)

foi aplicado nenhum rendimento sobre a parte não alocada do capital.

Assim, o primeiro nível de comparação é verificar se as estratégias implementadas, utilizando do Sistema de Gestão de Risco, apresentaram melhor retorno financeiro líquido que o *baseline* primário.

A segunda dimensão de *baseline* consiste em mensurar o efeito do Sistema de Gestão de Risco sobre a execução da estratégia sem o SGR. Ou seja, verificar como a taxa de acerto, relação risco/ganho, quantidade de operações e retorno financeiro bruto e líquido foram impactados pelo uso do SGR.

Capítulo 5

Análise dos Resultados

Neste capítulo serão apresentados os resultados obtidos durante a execução do processo metodológico apresentado no Capítulo 4.

A Seção 5.1 abrirá o capítulo apresentando a análise estatística de dados realizada sobre os cinco ativos da dissertação, abordando as análises, os testes realizados e os sumários estatísticos gerados. Na seção seguinte (Seção 5.2) serão apresentados os resultados obtidos no treinamento dos modelos de aprendizado profundo e o modelo de predição selecionado para cada ativo. Uma análise estatística mais detalhada dos modelos treinados foi reservada ao Apêndice A.

Na sequência, a Seção 5.3 apresenta a análise detalhada da distribuição de erros percentuais dos valores máximos e mínimos previstos pelos modelos selecionados para cada ativo, ao passo que a Seção 5.4 revela os parâmetros otimizados de cada estratégia automatizada para cada ativo.

O resultado do *backtesting* é exposto na Seção 5.5, a qual inicia com a definição dos *baselines*, em seguida apresenta o resultado das estratégias automatizadas sem a utilização do sistema de gestão de risco (SGR) e com a utilização do mesmo, bem como a análise desses resultados.

Por fim, a Seção 5.6 encerra o capítulo através das considerações finais.

5.1 Análise estatística dos dados

A análise estatística dos dados foi conduzida para buscar revelar informações importantes sobre o valor máximo e mínimo de um ativo em determinado dia.

Inicialmente, realizou-se o sumário estatístico das variáveis de log retorno a serem utilizadas para treinamento dos modelos LSTM e BiLSTM, apresentadas na Tabela 4.1. As Tabelas 5.1 a 5.5 apresentam as propriedades estatísticas gerais das variáveis de log retorno para cada um dos cinco ativos.

Em seguida, foram realizados testes de normalidade Shapiro-Wilk ([Shapiro and](#)

Wilk [1965]) a fim de verificar se as variáveis aleatórias de log-retorno possuíam distribuição normal. Verificou-se que a hipótese nula de que as amostras das variáveis apresentam distribuição normal foi rejeitada para todas as variáveis de entrada de treinamento dos modelos e em todos os ativos.

Outro teste realizado sobre as variáveis de log-retorno foi o teste de estacionariedade *Augmented Dickey-Fuller* (Fuller [2009]), o qual resultou que todas as variáveis em todos os ativos apresentam estacionariedade.

Geralmente, os modelos de regressão assumem que os dados são estacionários e normalmente distribuídos (Trevor Hastie [2009]), apresentando melhores resultados nessa situação. Embora tenha sido verificado que as variáveis de log-retorno não são uniformemente distribuídas, decidiu-se por não realizar nenhuma transformação nessas variáveis.

Tabela 5.1: ABEV3 - Resumo estatístico das variáveis de log-retorno

	$L_{o,c}$	$L_{h,c}$	$L_{l,c}$	L_c	L_o	L_h	L_l	L_g	L_q
Média	0.00052	0.012367	-0.011679	0.000593	0.000604	0.000604	0.000596	0.000516	0.001616
Desvio padrão	0.008586	0.012652	0.012805	0.016937	0.017506	0.01409	0.01568	0.008586	0.477987
Mínimo	-0.106768	-0.053783	-0.146982	-0.144739	-0.191667	-0.101174	-0.141186	-0.106768	-1.869243
25%	-0.003495	0.004829	-0.017168	-0.008403	-0.008986	-0.006124	-0.006631	-0.003499	-0.312774
50%	0	0.010159	-0.009881	0	0	0	0.000736	0	-0.010949
75%	0.004367	0.017571	-0.003956	0.009762	0.010282	0.007435	0.008054	0.004352	0.303581
Máximo	0.084993	0.135254	0.047253	0.13077	0.23713	0.108041	0.223144	0.084993	2.632997
Qtde de amostras	2738 dias								

Fonte: Elaborada pelo autor (2022)

Tabela 5.2: B3SA3 - Resumo estatístico das variáveis de log-retorno

	$L_{o,c}$	$L_{h,c}$	$L_{l,c}$	L_c	L_o	L_h	L_l	L_g	L_q
Média	0.000444	0.015707	-0.015112	0.000552	0.000558	0.00056	0.000557	0.000443	0.000151
Desvio padrão	0.01234	0.016488	0.017205	0.022219	0.022727	0.019097	0.020213	0.01234	0.507995
Mínimo	-0.22051	-0.051593	-0.235652	-0.100295	-0.221514	-0.096127	-0.225049	-0.22051	-1.718629
25%	-0.005044	0.005404	-0.023288	-0.01271	-0.012527	-0.010134	-0.010599	-0.005044	-0.321073
50%	0.000554	0.013101	-0.01281	0	0	0	0.001117	0.000554	-0.007009
75%	0.006119	0.023501	-0.004305	0.013866	0.013539	0.010372	0.012192	0.006119	0.332163
Máximo	0.136006	0.136006	0.06522	0.097727	0.151912	0.136006	0.139237	0.136006	2.401319
Qtde de amostras	2243 dias								

Fonte: Elaborada pelo autor (2022)

Para a análise da correlação cruzada entre as variáveis, realizou-se um deslocamento para negativo de 1 unidade das variáveis L_{hc} e L_{lc} , que são as variáveis a serem preditas pelos modelos deep learning, de forma que o valor do log retorno dos valores máximos e mínimos do dia atual pudessem ser avaliados em relação aos dados disponíveis do dia anterior. Em outras palavras, calculou-se a correlação cruzada das demais variáveis em relação às variáveis de saída dos modelos com 1 unidade de atraso.

Os mapas de calor gerados encontram-se no Apêndice B e observou-se um padrão muito semelhante em todos os ativos. As duas variáveis mais correlacionadas com o log

Tabela 5.3: ITUB4 - Resumo estatístico das variáveis de log-retorno

	$L_{o,c}$	$L_{h,c}$	$L_{l,c}$	L_c	L_o	L_h	L_l	L_g	L_q
Média	0.000697	0.014528	-0.014025	0.000511	0.000519	0.000518	0.000526	0.000704	0.000668
Desvio padrão	0.013748	0.017977	0.019026	0.023032	0.023919	0.019648	0.02184	0.013746	0.432898
Mínimo	-0.219282	-0.093678	-0.219282	-0.126798	-0.25353	-0.150744	-0.211513	-0.219282	-1.879559
25%	-0.004824	0.004535	-0.021347	-0.011563	-0.011296	-0.009372	-0.009696	-0.004818	-0.268902
50%	0.000451	0.011767	-0.011653	0	0	0	0	0.000456	-0.015464
75%	0.006723	0.0214	-0.003484	0.012174	0.012496	0.01015	0.010882	0.006731	0.251432
Máximo	0.142156	0.21929	0.10599	0.21929	0.204458	0.1555	0.192553	0.142156	2.533816
Qtde de amostras	2738 dias								

Fonte: Elaborada pelo autor (2022)

Tabela 5.4: PETR4 - Resumo estatístico das variáveis de log-retorno

	$L_{o,c}$	$L_{h,c}$	$L_{l,c}$	L_c	L_o	L_h	L_l	L_g	L_q
Média	0.00147	0.017943	-0.016625	-0.000042	-0.000029	-0.000036	-0.000036	0.001465	0.000621
Desvio padrão	0.017469	0.022128	0.023747	0.029567	0.030751	0.025657	0.027528	0.017467	0.373976
Mínimo	-0.227136	-0.12988	-0.240617	-0.17482	-0.223144	-0.164982	-0.219805	-0.227136	-1.848465
25%	-0.005178	0.006005	-0.025641	-0.015253	-0.015176	-0.011643	-0.01259	-0.005178	-0.239711
50%	0.001744	0.013703	-0.012753	0	0	0	0.00085	0.001744	-0.014299
75%	0.008404	0.026869	-0.003231	0.015386	0.015508	0.011346	0.013472	0.008403	0.232949
Máximo	0.182584	0.187212	0.092423	0.1531	0.299579	0.187212	0.184208	0.182584	1.66925
Qtde de amostras	2739 dias								

Fonte: Elaborada pelo autor (2022)

Tabela 5.5: USIM5 - Resumo estatístico das variáveis de log-retorno

	$L_{o,c}$	$L_{h,c}$	$L_{l,c}$	L_c	L_o	L_h	L_l	L_g	L_q
Média	0.002254	0.02356	-0.02141	-0.000342	-0.000328	-0.000332	-0.000329	0.002256	0.000761
Desvio padrão	0.017012	0.02693	0.026388	0.035885	0.038345	0.032813	0.034234	0.017013	0.417209
Mínimo	-0.19761	-0.120296	-0.248727	-0.169984	-0.227894	-0.253273	-0.232403	-0.19761	-1.861419
25%	-0.005198	0.008084	-0.033546	-0.020317	-0.020753	-0.017302	-0.018284	-0.005198	-0.263725
50%	0.00225	0.018584	-0.017361	-0.001985	-0.000986	-0.000968	0	0.00225	-0.017453
75%	0.009918	0.033054	-0.005165	0.018312	0.019413	0.015284	0.017402	0.009926	0.251735
Máximo	0.215111	0.319431	0.134348	0.295714	0.50013	0.308735	0.300892	0.215111	1.837055
Qtde de amostras	2738 dias								

Fonte: Elaborada pelo autor (2022)

retorno do valor máximo em relação ao valor de fechamento (L_{hc}) anterior são: L_c e L_h . A terceira variável mais correlacionadas variou entre L_l , L_{oc} e L_{lc} . Ao passo que as duas variáveis mais correlacionadas com o log retorno do valor mínimo em relação ao valor de fechamento (L_{lc}) anterior são: L_c e L_l . Neste caso, a terceira variável mais correlacionada variou entre L_{oc} , L_{hc} e L_h .

Realizou-se uma análise qualitativa dos gráficos de distribuição e de dispersão apresentados no Apêndice B, validando os achados anteriores.

Por fim, realizou-se a análise da distribuição dos retornos percentuais dos valores máximos em relação ao preço de abertura, dos valores mínimos em relação ao preço de abertura e retorno percentual entre o valor máximo e mínimo em um mesmo dia, visando

mensurar o intervalo de oscilação de preço do ativo em um dado dia. As tabelas 5.6, 5.7 e 5.8 apresentam esses dados respectivamente. Os gráficos da distribuição de retornos encontram-se no Apêndice B.

Tabela 5.6: Análise de percentil da distribuição de retornos percentuais do valor máximo em relação ao preço de abertura do ativo

Ativo	Percentil da distribuição de retornos				
	75%	80%	85%	90%	95%
ABEV3	1.67%	1.89%	2.17%	2.53%	3.15%
B3SA3	2.28%	2.60%	3.00%	3.49%	4.12%
ITUB4	1.84%	2.07%	2.39%	2.75%	3.50%
PETR4	2.17%	2.48%	2.95%	3.54%	4.99%
USIM5	2.99%	3.49%	4.07%	4.90%	6.62%

Fonte: Elaborada pelo autor (2022)

Tabela 5.7: Análise de percentil da distribuição de retornos percentuais do valor mínimo em relação ao preço de abertura do ativo

Ativo	Percentil da distribuição de retornos				
	75%	80%	85%	90%	95%
ABEV3	-1.75%	-1.96%	-2.24%	-2.55%	-3.18%
B3SA3	-2.32%	-2.53%	-2.89%	-3.39%	-4.10%
ITUB4	-1.92%	-2.16%	-2.46%	-2.93%	-3.54%
PETR4	-2.30%	-2.62%	-3.02%	-3.56%	-4.53%
USIM5	-3.11%	-3.58%	-4.12%	-4.70%	-5.69%

Fonte: Elaborada pelo autor (2022)

Tabela 5.8: Análise de percentil da distribuição de retornos percentuais do valor máximo em relação ao valor mínimo do ativo em base diária

Ativo	Percentil da distribuição de retornos								
	5%	10%	15%	20%	50%	80%	85%	90%	95%
ABEV3	1.11%	1.27%	1.41%	1.55%	2.19%	3.18%	3.49%	3.86%	4.82%
B3SA3	1.49%	1.73%	1.93%	2.08%	3.05%	4.28%	4.59%	5.11%	6.03%
ITUB4	1.29%	1.49%	1.63%	1.74%	2.45%	3.53%	3.86%	4.24%	4.96%
PETR4	1.34%	1.55%	1.71%	1.87%	2.86%	4.48%	5.03%	5.95%	7.40%
USIM5	1.81%	2.12%	2.43%	2.64%	3.99%	5.93%	6.65%	7.73%	9.69%


Fonte: Elaborada pelo autor (2022)

Ainda relacionado ao estudo estatístico dos dados, foi realizado um estudo nos dados de treino sobre a tendência diária dos ativos. Foram calculadas as probabilidades

condicionais de que a tendência diária seja de baixa (preço de fechamento diário seja menor que preço de abertura), dado que a tendência até determinado horário de negociação é de baixa (preço no horário seja menor que preço da abertura), bem como para situação de alta. Pelos gráficos das Figuras 5.1 e 5.1 verifica-se para todos os ativos analisados que a tendência para cada encerramento de hora de negociação tende a ser confirmada na tendência diária com probabilidades maiores que 60%, aumentando a medida que transcorre o tempo de negociação do mercado.


Embora seja um achado interessante, é importante ressaltar que não necessariamente haverá uma apreciação ou depreciação monotonicamente crescente/descrescente no preço do ativo ao longo do dia. Por exemplo, caso o preço de abertura do ativo PETR4 seja R\$ 10,00 e às 12 horas sua cotação esteja à R\$ 9,80, há naquele momento aproximadamente 75% de chance que o preço do ativo encerre abaixo de R\$ 10,00. Uma operação de venda ao preço de R\$ 9,80 e encerrada no fechamento pode não refletir em uma operação lucrativa, pois o preço do ativo poderia fechar em R\$ 9,95 e ainda correspondendo às chances inicialmente calculadas. Assim, o estudo de probabilidade condicional realizado pode ser indicativo de tipo de operação com maior chance de sucesso, embora não seja garantido.

Figura 5.1: Gráfico apresenta a probabilidade condicional de que a tendência diária seja de baixa dado que a tendência até determinado horário de negociação é de baixa



Fonte: Elaborada pelo autor (2022)

Figura 5.2: Gráfico apresenta a probabilidade condicional de que a tendência diária seja de alta dado que a tendência até determinado horário de negociação é de alta



Fonte: Elaborada pelo autor (2022)

5.2 Treinamento dos modelos de predição

Conforme elucidado na Seção 4.5, o treinamento dos modelos de predição foi realizado de tal forma a obter um modelo otimizado em termos da métrica de erro médio quadrático (RMSE). Assim, após a execução de treinamento de 7.200 combinações de estrutura de modelos/dados de entrada para cada ativo, foram selecionados os 5 modelos para cada conjunto de dado de entrada que apresentaram o menor valor de RMSE nos dados de validação, totalizando 20 modelos para cada ativo.

Em uma segunda etapa do processo, os modelos foram treinados 10 vezes com diferentes combinações dos dados de treino e validação, a fim de obter a média do valor de RMSE. A Tabela 5.9 apresenta o resultado final desse processo, bem como a estrutura dos modelos de predição selecionados para compor o sistema de gestão de risco.

De forma geral, observa-se que o conjunto de dados de entrada que ensejou a seleção de modelos com menores valores de RMSE para todos os ativos foram os dados de log-retorno OHLCV. Em relação à estrutura dos modelos de predição, observou-se uma prevalência da rede LSTM sem aplicação do mecanismo de atenção, exceto no caso do ativo PETR4, no qual o modelo selecionado foi uma rede BiLSTM com mecanismo de atenção. Em todos os casos, os modelos selecionados apresentaram apenas 1 camada e fatores de células pequenos e próximos ao tamanho da janela temporal de dados de entrada.

Em relação ao tamanho da janela temporal de dados dos modelos, observou-se

Tabela 5.9: Média e desvio padrão do valor de RMSE dos modelos de predição selecionados para cada ativo

Ativos	Variáveis de Entrada				Estrutura do Modelo
	OHLCV	OHLCV + Var. adicionais	OHLCV + Ind. Técnicos	OHLCV + Var. adicionais + Ind. Técnicos	
ABEV3	0.10775 ± 0.00479	0.10848 ± 0.00420	0.10977 ± 0.00263	0.11013 ± 0.00488	LSTM, janela=29, camadas=1, fator de células=3
B3SA3	0.18909 ± 0.00701	0.19336 ± 0.00633	0.18916 ± 0.00857	0.19014 ± 0.00807	LSTM, janela=10, camadas=1, fator de células=1
ITUB4	0.17534 ± 0.00669	0.17799 ± 0.00388	0.17877 ± 0.00652	0.17939 ± 0.00894	LSTM, janela=23, camadas=1, fator de células=2
PETR4	0.28049 ± 0.00800	0.28291 ± 0.00864	0.28863 ± 0.00745	0.28348 ± 0.01229	BILSTM+ATT, janela=6, camadas=1, fator de células=1
USIM5	0.19006 ± 0.00449	0.19799 ± 0.00816	0.19073 ± 0.00996	0.19634 ± 0.00924	LSTM, janela=12, camadas=1, fator de células=2

Fonte: Elaborada pelo autor (2022)

tamanhos distintos variando de 6 dias (no caso do ativo PETR4) a 29 dias (caso do ativo ABEV3).

Uma análise estatística geral de todos os 36 mil modelos treinados visando identificar características que levam a modelos com melhor desempenho de RMSE foi realizada e está apresentada no Apêndice A.

5.3 Análise estatística do desempenho dos preditores

A análise estatística de desempenho dos preditores selecionados para os ativos é fundamental para mensurar a qualidade do sistema de gestão de risco, uma vez que o mesmo depende diretamente das predições dos modelos. Um modelo de predição que seja pouco preciso e que apresente uma cauda na distribuição de erros longa, provavelmente, não cumprirá com qualidade o papel de gerir risco, pois poderá errar as regiões de preço mínimo e máximo do ativo, filtrando de forma incorreta operações sugeridas pelas estratégias automatizadas.

As Tabelas 5.10 e 5.11 apresentam as análises de percentil da distribuição de erros percentuais dos valores preditos de preço máximo e mínimo dos ativos no conjuntos de dados de validação. É importante salientar que foi realizado um corte na cauda da distribuição de 10% dos dados em cada extremidade, a fim de obter uma visão das situações mais frequentes (80% das situações), minimizando o efeito de erros muito grandes do preditor, seja por situações atípicas de mercado (tais como oscilações muito bruscas devido

a eventos políticos, catastrofes ou notícias sobre o ativo) ou por próprio erro do preditor. Além disso, as tabelas também apresentam o corte da distribuição de erros segregado para os dias onde houve tendência de alta (preço de fechamento maior que preço da abertura) e dias de baixa.

Verifica-se para todos os modelos que os erros de predição do valor mínimo nos dias com tendência de alta são negativos, ou seja, geralmente os modelos prevêem um valor mínimo menor do que o valor mínimo ocorrido de fato. Isto impacta bastante o sistema de gestão de risco, pois a operação desejada em dias de alta seriam compras e de preferência próximas ao valor mínimo. Caso a região de operação de compra entorno do valor mínimo previsto, sugerida pelo sistema de gestão de risco, seja muito estreita, podem não ser aproveitadas as melhores oportunidades nesses dias ou até mesmo não serem realizadas operações de compra.

Ainda em relação aos dias de tendência de alta, a tabela 5.11 permite identificar que a previsão do valor máximo é geralmente subestimada, ou seja, menor do que o valor real do preço máximo. Esta característica na distribuição dos erros não é interessante, pois a cotação dos ativos pode alcançar o valor máximo previsto e acarretar na abertura de operações de venda em dias com tendência de alta de forma equivocada, gerando prejuízos.

Quando se analisa a distribuição de erros de predição nos dias com tendência de baixa, observa-se que para a predição dos valores máximos diários que os erros são positivos a partir do percentil 10% para todos os ativos, o que sinaliza que a previsão do valor máximo é quase sempre sobreestimada, maior que o valor máximo real. Isso pode acarretar em situações nas quais o sistema de gestão de risco não enxergará oportunidades de vendas em dias de tendência de baixa, reduzindo o desempenho na gestão de risco pois não realizará as operações com maior potencial de lucro no dia. Em relação à previsão dos valores mínimo em dias de baixa, em 70% ou mais das situações o erro de predição é positivo, indicando que as previsões do valor mínimo costumam ser sobreestimadas. Isso pode acarretar na aceitação de operações de compra em dias de tendência de baixa, ensejando em operações que resultarão em prejuízos.

Em suma, as distribuições dos erros de predição apontam para um cenário desfavorável para utilização direta das previsões fornecidas pelos modelos. Além disso, verifica-se que a faixa de erros, tanto para a predição de valores mínimos e máximos varia aproximadamente entre 2 % e 4 % (dependendo do ativo). Essa magnitude de erro dificulta substancialmente a construção de um sistema de gestão de risco dado que encontra-se na mesma ordem de grandeza do intervalo entre valor máximo e mínimo reais em 50 % das situações. Portanto, embora fosse desejável modelos que fornecessem previsões mais precisas, a utilização dos modelos, obtidos após extenso trabalho de otimização, como parte de um sistema de gestão de risco, exigirá algum manejo na tentativa de obter um resultado financeiro satisfatório em função da gestão de risco aplicada, levando em consideração às incertezas envolvidas.

Por fim, as figuras 5.3 a 5.3 apresentam as distribuições completas dos erros percentuais de predição para cada ativo. Observa-se que, evidentemente, as distribuições não normais. As distribuições de erros de predição dos valores máximos possuem cauda à esquerda, enquanto as distribuições de erros de predição dos valores mínimos possuem cauda à direita. O que reflete no valor da mediana (percentil 50% não ser próximo de zero).

Entre os ativos, o modelo de ABEV3 apresentou melhor resultado em termos de erros de predição do valor máximo com um intervalo de erro igual a 2,12% (Valor máximo - valor mínimo) e 2,06% para o intervalo de erro da predição do valor mínimo. Em contrapartida, o modelo do ativo USIM5 apresentou erros maiores de predição, sendo o intervalo de erro do valor máximo previsto de 4,06% e do valor mínimo 4,10%.

Tabela 5.10: Predição do valor mínimo - Análise de percentil da distribuição de erros percentuais de predição (eliminando 10% das caudas em cada extremidade)

Ativo	Valor mínimo	10%	20%	30%	40%	50%	60%	70%	80%	90%	Valor máximo
ABEV3	-0.88	-0.74	-0.59	-0.45	-0.3	-0.15	0	0.15	0.41	0.69	1.23
Tendência de alta	-1.03	-0.88	-0.81	-0.74	-0.63	-0.53	-0.49	-0.36	-0.22	-0.09	0.15
Tendência de baixa	-0.31	-0.15	0	0.07	0.25	0.37	0.5	0.68	0.96	1.32	1.58
B3SA3	-1.33	-1.13	-0.92	-0.75	-0.6	-0.4	-0.11	0.17	0.51	0.82	1.34
Tendência de alta	-1.66	-1.34	-1.24	-1.11	-0.97	-0.92	-0.81	-0.72	-0.53	-0.4	-0.13
Tendência de baixa	-0.68	-0.53	-0.14	0	0.19	0.41	0.6	0.85	1.2	1.4	1.94
ITUB4	-1.52	-1.21	-1.08	-0.87	-0.58	-0.38	-0.21	0.13	0.64	1.28	1.86
Tendência de alta	-1.93	-1.52	-1.38	-1.16	-1.12	-1.02	-0.86	-0.64	-0.48	-0.34	-0.12
Tendência de baixa	-0.92	-0.54	-0.25	0	0.15	0.49	0.83	1.33	1.56	1.97	2.45
PETR4	-1.76	-1.27	-1.09	-0.85	-0.64	-0.45	-0.2	0.12	0.83	1.58	2.72
Tendência de alta	-2.1	-1.76	-1.45	-1.25	-1.15	-1.07	-0.92	-0.74	-0.56	-0.44	-0.12
Tendência de baixa	-0.96	-0.66	-0.41	-0.2	0	0.46	0.97	1.51	1.96	2.7	3.66
USIM5	-1.94	-1.5	-1.22	-1	-0.81	-0.5	-0.21	0.21	0.74	1.38	2.29
Tendência de alta	-2.4	-2.02	-1.85	-1.55	-1.44	-1.32	-1.12	-0.93	-0.8	-0.51	-0.06
Tendência de baixa	-1.02	-0.71	-0.49	-0.24	0.15	0.42	0.88	1.28	1.57	2.15	3.23

Fonte: Elaborada pelo autor (2022)

5.4 Implementação de estratégias automatizadas


Conforme abordado na Seção 4.8, foram implementadas 7 estratégias automatizadas para gerar sinais de compras e vendas. As estratégias foram otimizadas por ativo sobre os dados de treino/validação, utilizando a técnica *Grid search*, definindo assim os melhores parâmetros para cada estratégia, de forma a maximizar o critério de Kelly, seguido da taxa de acerto e relação risco/ganho das operações.

Tabela 5.11: Predição de valor máximo - Análise de percentil da distribuição de erros percentuais de predição (eliminando 10% das caudas em cada extremidade)

Ativo	Valor mínimo	10%	20%	30%	40%	50%	60%	70%	80%	90%	Valor máximo
ABEV3	-1.01	-0.74	-0.46	-0.21	0	0.11	0.31	0.42	0.62	0.75	0.94
Tendência de alta	-1.2	-1.02	-0.89	-0.71	-0.51	-0.4	-0.21	-0.07	0	0.25	0.42
Tendência de baixa	0	0.09	0.28	0.4	0.48	0.57	0.7	0.75	0.81	0.97	1.11
B3SA3	-1.32	-0.7	-0.47	-0.22	0	0.18	0.34	0.53	0.68	0.89	1.11
Tendência de alta	-1.79	-1.43	-0.99	-0.73	-0.59	-0.45	-0.23	-0.12	0	0.18	0.34
Tendência de baixa	-0.22	0.14	0.34	0.51	0.58	0.67	0.78	0.9	1.02	1.12	1.21
ITUB4	-1.65	-1.15	-0.9	-0.57	-0.22	0.05	0.29	0.47	0.7	0.91	1.22
Tendência de alta	-2.74	-1.79	-1.36	-1.21	-1	-0.88	-0.77	-0.57	-0.33	-0.09	0.05
Tendência de baixa	0	0.22	0.34	0.45	0.55	0.69	0.83	0.93	1.04	1.24	1.54
PETR4	-2.59	-1.48	-0.84	-0.39	0	0.23	0.4	0.62	0.84	1.11	1.73
Tendência de alta	-3.76	-2.82	-1.91	-1.6	-1.27	-0.91	-0.55	-0.25	0.21	0.42	0.66
Tendência de baixa	-0.39	0	0.15	0.29	0.46	0.62	0.84	0.91	1.12	1.56	2.01
USIM5	-2.07	-1.13	-0.75	-0.35	0	0.24	0.49	0.69	0.95	1.13	1.53
Tendência de alta	-3.66	-2.78	-1.95	-1.4	-0.99	-0.8	-0.62	-0.4	-0.16	0.08	0.48
Tendência de baixa	-0.12	0.23	0.37	0.52	0.63	0.76	0.97	1.1	1.31	1.51	1.84

Fonte: Elaborada pelo autor (2022)


Figura 5.3: ABEV3 - Distribuição dos erros de predição do modelo selecionado para o preço máximo e mínimo diário nos dados de validação



Fonte: Elaborada pelo autor (2022)


A Tabela 5.12 apresenta o resultado da otimização dos parâmetros de cada estratégia. Observa-se que a maior parte das estratégias apresentou uma taxa de acerto entre 30% a 40% e relação de risco/ganho entre 0,9 e 1,4. A aplicação do critério de Kelly nessas situações gera valor negativo, pois não há expectativa de ganho a longo prazo na

Figura 5.4: B3SA3 - Distribuição dos erros de predição do modelo selecionado para o preço máximo e mínimo diário nos dados de validação




Fonte: Elaborada pelo autor (2022)

Figura 5.5: ITUB4 - Distribuição dos erros de predição do modelo selecionado para o preço máximo e mínimo diário nos dados de validação




Fonte: Elaborada pelo autor (2022)

Figura 5.6: PETR4 - Distribuição dos erros de predição do modelo selecionado para o preço máximo e mínimo diário nos dados de validação



Fonte: Elaborada pelo autor (2022)

Figura 5.7: PETR4 - Distribuição dos erros de predição do modelo selecionado para o preço máximo e mínimo diário nos dados de validação



Fonte: Elaborada pelo autor (2022)

recorrência de operações com esse resultado esperado.

As estratégias apresentaram quantidade de operações bem distintas, variando entre 300 e 28 mil, em um intervalo de dados de 2.000 a 2500 dias, dependendo do ativo. Isso dá uma relação que varia de aproximadamente 1 operação a cada 7 dias até 13 operações por dia. Nota-se que apenas as estratégias RSI, MACD (Posicionado) obtiveram taxa de acerto e relação de risco/ganho favoráveis o suficiente para haver expectativa de ganho a longo prazo. Nesses casos o critério de Kelly foi calculado entre 12,6% a 42,5% do capital total. Também foram as estratégias que realizaram operações mais longas, não consistindo em operações intradiárias.

A estratégia *Buy low/Sell high*, a qual utiliza os modelos de predição treinados neste trabalho, resultou em melhores taxas de acerto e relação risco/ganho em comparação às demais estratégias. O valor do critério de Kelly calculado variou entre 85 a 92%, ao passo que a quantidade de operações representou a relação de aproximadamente um *trade* a cada 2 dias.

Para a definição do baseline da estratégia e backtesting da estratégia com o sistema de gestão de risco aplicado, serão utilizados os parâmetros da tabela 5.12, bem como será adotado no início do backtesting um tamanho de posição referente à 30% do critério de Kelly. No caso de estratégias que não obtiveram uma taxa de acerto e risco ganho favoráveis, a estratégia iniciará com operações de 2% do capital total, o que seria equivalente ao valor do critério de Kelly para uma situação hipotética de risco ganho 1-1 e taxa de acerto de 51%.

5.5 Resultados do *Backtesting*

Esta seção iniciará com a Subseção 5.5.1 a qual apresentará a definição da janela temporal de *backtesting* e dos *baselines* dos ativos, utilizando a estratégia *buy and hold* (*baseline* primário), bem como a comparação do desempenho das estratégias automatizadas sem aplicação do sistema de gestão de risco (SGR) e com a utilização do SGR (*baseline* secundário).

Em seguida, a Subseção 5.5.2 apresentará a análise do impacto da utilização do SGR para cada estratégia automatizada e para cada um dos cinco ativos selecionados. Será dada ênfase ao melhor e pior caso de utilização do SGR para cada um dos ativos, abordando o impacto do SGR nas estratégias em termos do tipo de operação (compra/venda) e retorno da operação (positivo/negativo).

Tabela 5.12: Parâmetros otimizados para cada estratégia e ativo a ser executada no *backtesting*.

Ativo (Qtde dias)	Estratégia	Critério de Kelly	Taxa de acerto	RG	Qtde de operações	Parâmetros
ABEV3 2520 dias	Buy low/Sell High	-	33.12	1.28	1141	LSTM, jan.=29, cam.=1, fator de células=3
	Act on opening	7.7	49.56	1.205	2520	LSTM, jan.=2, cam.=1, fator de células=10
	Cruzamento de média	-	33.09	1.14	27979	pslow=2
	Cruzamento de 2 médias	-	35.81	1.09	10037	pfast=4/pslow=8
	Cruzamento de 3 médias (C/ liquidação)	-	33.21	0.8	2827	pfastest=6/pfast=13/pslow=27
	Cruzamento de 3 médias (Posicionado)	-	35.83	1.05	5593	pfastest=3/pfast=6/pslow=11
	RSI	42.5	64.58	1.61	384	n_per=4/lower=25/upper=70
MACD (C/ liquidação)	-	32.87	0.9	3684	macd1=12/macd2=26/signal=9	
MACD (Posicionado)	38	64.23	1.36	1675	macd1=5/macd2=13/signal=3	
B3SA3 2035 dias	Buy low/Sell High	-	31.37	1.063	443	LSTM, jan.=10, cam.=1, fator de células=1
	Act on opening	-	47.42	1.017	2035	LSTM, jan.=3, cam.=3, fator de células=10
	Cruzamento de média	-	35.11	1.11	21068	pslow=3
	Cruzamento de 2 médias	-	39.58	1.18	6563	pfast=5/pslow=10
	Cruzamento de 3 médias (C/ liquidação)	-	39.54	1.26	1894	pfastest=7/pfast=15/pslow=30
	Cruzamento de 3 médias (Posicionado)	-	40.87	1.23	1715	pfastest=7/pfast=14/pslow=28
	RSI	34.9	61.66	1.43	300	n_per=4/lower=25/upper=75
MACD (C/ liquidação)	-	35.66	1	2672	macd1=14/macd2=26/signal=10	
MACD (Posicionado)	29.1	61.38	1.19	1313	macd1=9/macd2=21/signal=6	
ITUB4 2464 dias	Buy low/Sell High	-	33.12	1.109	646	LSTM, jan.=23, cam.=1, fator de células=2
	Act on opening	-	47.8	1.003	2464	LSTM, jan.=2, cam.=2, fator de células=1
	Cruzamento de média	-	34.08	1.13	30676	pslow=2
	Cruzamento de 2 médias	-	37.45	1.14	8058	pfast=5/pslow=10
	Cruzamento de 3 médias (C/ liquidação)	-	39.15	1.11	2646	pfastest=7/pfast=14/pslow=27
	Cruzamento de 3 médias (Posicionado)	-	40.09	1.28	1823	pfastest=7/pfast=16/pslow=33
	RSI	35	62.14	1.39	280	n_per=4/lower=30/upper=80
MACD (C/ liquidação)	-	35.83	0.95	3424	macd1=14/macd2=25/signal=9	
MACD (Posicionado)	28.4	62.2	1.11	1651	macd1=8/macd2=15/signal=3	
PETR4 2524 dias	Buy low/Sell High	-	33.45	1.107	529	BILSTM+ATT, jan.=6, cam.=1, fator de células=1
	Act on opening	-	46.03	0.888	2524	LSTM, jan.=2, cam.=1, fator de células=1
	Cruzamento de média	-	37.83	1.23	26735	pslow=3
	Cruzamento de 2 médias	-	38.91	1.21	19660	pfast=2/pslow=4
	Cruzamento de 3 médias (C/ liquidação)	-	40.04	1.18	2305	pfastest=7/pfast=15/pslow=31
	Cruzamento de 3 médias (Posicionado)	-	40.61	1.32	1950	pfastest=7/pfast=15/pslow=31
	RSI	33.9	64.31	1.17	538	n_per=4/lower=25/upper=70
MACD (C/ liquidação)	-	35.99	0.99	3262	macd1=14/macd2=26/signal=10	
MACD (Posicionado)	19.2	58.62	1.05	1443	macd1=14/macd2=26/signal=10	
USIM5 2460 dias	Buy low/Sell High	-	30.9	1.015	440	LSTM, jan.=12, cam.=1, fator de células=2
	Act on opening	13.8	53.61	1.167	2460	LSTM, jan.=2, cam.=1, fator de células=2
	Cruzamento de média	-	37.13	1.25	25443	pslow=3
	Cruzamento de 2 médias	-	39.2	1.39	5589	pfast=7/pslow=14
	Cruzamento de 3 médias (C/ liquidação)	2.8	40.25	1.59	2119	pfastest=7/pfast=16/pslow=31
	Cruzamento de 3 médias (Posicionado)	8.1	42.8	1.65	1785	pfastest=7/pfast=16/pslow=31
	RSI	26.9	64.76	0.93	298	n_per=4/lower=20/upper=70
MACD (C/ liquidação)	-	34.67	1.03	3377	macd1=12/macd2=26/signal=9	
MACD (Posicionado)	12.6	61.11	0.8	1376	macd1=6/macd2=15/signal=4	

Fonte: Elaborada pelo autor (2022)

5.5.1 *Baselines*

Para a realização do *backtesting*, foi selecionada a janela temporal de 02/04/2019 a 30/12/2019 compreendendo 273 dias corridos e 187 dias de negociação. A Tabela 5.13 apresenta os *baselines* primários de retorno financeiro, que consistem na compra do ativo no primeiro dia da janela de teste e venda no preço de fechamento do último dia (estratégia

buy-and-hold), para as situações de 2%, 5%, 10%, 20 % e 30% do capital total (R\$ 100.000,00) alocado no ativo. Os gráficos dos cenários de teste estão apresentados no Apêndice C.

Tabela 5.13: Tabela de *baselines* primários para os ativos no *backtesting*

Tipo de Cenário	Baseline - Estratégia BUY AND HOLD (% alocado no ativo)				
	2%	5%	10%	20%	30%
ABEV3	0.24	0.61	1.22	2.43	3.65
B3SA3	0.65	1.62	3.24	6.47	9.71
ITUB4	0.23	0.57	1.13	2.26	3.40
PETR4	0.20	0.51	1.02	2.04	3.06
USIM5	-0.14	-0.36	-0.72	-1.43	-2.15

Fonte: Elaborada pelo autor (2022)

Para o estabelecimento dos *baselines* secundários, foram executadas as estratégias automatizadas, utilizando os gatilhos de compra e venda e tamanho de exposição de 30% do critério de Kelly alcançado na otimização, sem adoção de *stoploss*. A Tabela 5.14 apresenta o resultado da execução das estratégias ainda sem a aplicação da camada do sistema de gestão de risco.

Verifica-se na Tabela 5.14 as estratégias que superaram o *baseline* primário em termos de retorno financeiro líquido (em cinza) e a estratégia com melhor desempenho (em verde). As estratégias RSI e MACD apresentaram com maior frequência resultados melhores do que o *baseline* primário, tendo a estratégia RSI sido a melhor alternativa para 4 dos 5 ativos. Essas estratégias realizam poucas operações e apresentam geralmente taxas de acerto entre 37 e 60 %. Devido ao fato de apresentarem relação risco/ganho maior do que 1, apresentaram resultado financeiro líquido positivo na maior parte dos ativos.

As demais estratégias apresentaram um número mais elevado de operações e taxas de acerto variando aproximadamente entre 14 e 50 %. Na maior parte dos casos apresentaram relação risco/ganho menor do que 1, resultando em perdas financeiros ao final do *backtesting*.

Na próxima seção, será apresentado o impacto da utilização do sistema de gestão de risco nas métricas de execução das estratégias automatizadas.

Tabela 5.14: Tabela de *baselines* secundários para os ativos no *backtesting*

Ativo	Estratégias	Retorno Bruto	Retorno Líquido	Qtde op.	Taxa de acerto	Risco/Ganho
ABEV3 Baseline primário: 0.24%	Buy low/Sell High	0%	-0.04%	29	34.5%	0.76
	Act on opening	0.15%	-0.11%	188	46.3%	0.95
	Cruzamento de média	1.77%	-1.35%	2427	32.1%	0.82
	Cruzamento de 2 médias	-0.37%	-1.35%	766	34%	0.7
	Cruzamento de 3 médias (C/ liquidação)	-0.13%	-0.36%	187	34.8%	0.7
	Cruzamento de 3 médias (Posicionado)	-0.18%	-0.6%	395	35.5%	0.77
	RSI	0.46%	0.29%	23	59.1%	1.08
	MACD (C/ liquidação)	-0.21%	-0.52%	262	30.3%	0.77
	MACD (Posicionado)	1.07%	0.22%	116	60.9%	1.03
B3SA3 Baseline primário: 0.65%	Buy low/Sell High	-0.04%	-0.06%	18	27.8%	0.5
	Act on opening	0.47%	0.24%	188	54.3%	1.1
	Cruzamento de média	1.26%	-1.6%	1873	32.6%	0.85
	Cruzamento de 2 médias	0.72%	-0.15%	568	35.3%	0.97
	Cruzamento de 3 médias (C/ liquidação)	0.38%	0.19%	160	39.4%	1.16
	Cruzamento de 3 médias (Posicionado)	-1.61%	-1.94%	150	30.9%	0.61
	RSI	3.64%	3.42%	27	61.5%	1.89
	MACD (C/ liquidação)	1.41%	1.16%	208	44%	1.57
	MACD (Posicionado)	-0.21%	-0.92%	107	62.3%	0.9
ITUB4 Baseline primário: 0.23%	Buy low/Sell High	0.04%	0.01%	25	36%	1.09
	Act on opening	-0.16%	-0.39%	188	45.2%	0.82
	Cruzamento de média	1.33%	-1.85%	2562	31.9%	0.78
	Cruzamento de 2 médias	-0.1%	-0.85%	613	34.5%	0.8
	Cruzamento de 3 médias (C/ liquidação)	-0.67%	-0.9%	193	28%	0.44
	Cruzamento de 3 médias (Posicionado)	-0.23%	-0.53%	152	40.4%	0.84
	RSI	0.98%	0.85%	21	60%	1.39
	MACD (C/ liquidação)	-0.25%	-0.54%	246	33.5%	0.77
	MACD (Posicionado)	0.54%	-0.1%	121	62.5%	0.99
PETR4 Baseline primário: 0.2%	Buy low/Sell High	0.01%	-0.01%	16	31.2%	0.91
	Act on opening	-0.46%	-0.68%	188	43.6%	0.71
	Cruzamento de média	1%	-1.26%	1926	32.2%	0.81
	Cruzamento de 2 médias	1.24%	-0.41%	1414	34.3%	0.92
	Cruzamento de 3 médias (C/ liquidação)	0.09%	-0.12%	176	34.9%	0.91
	Cruzamento de 3 médias (Posicionado)	-0.24%	-0.48%	154	32%	0.82
	RSI	-1.36%	-1.6%	41	55%	0.72
	MACD (C/ liquidação)	0.65%	0.4%	217	38.4%	1.19
	MACD (Posicionado)	3.13%	2.78%	105	66.3%	1.87
USIM5 Baseline primário: -0.14%	Buy low/Sell High	-0.04%	-0.07%	22	27.3%	0.56
	Act on opening	0.26%	-0.21%	188	52.7%	0.97
	Cruzamento de média	0.96%	-0.91%	1903	35.1%	0.86
	Cruzamento de 2 médias	-0.69%	-1.1%	418	35.7%	0.71
	Cruzamento de 3 médias (C/ liquidação)	0.37%	0.18%	154	35.1%	1.13
	Cruzamento de 3 médias (Posicionado)	-0.06%	-0.2%	135	34.3%	0.9
	RSI	1.14%	1.07%	18	58.8%	1.51
	MACD (C/ liquidação)	0.38%	0.08%	255	37.4%	1.03
	MACD (Posicionado)	-0.6%	-0.81%	112	62.2%	0.78

Fonte: Elaborada pelo autor (2022)

5.5.2 Aplicação do Sistema de Gestão de Risco (SGR) sobre estratégias

O Sistema de Gestão de Risco (SGR), conforme apresentado na seção 4.7, foi aplicado como uma segunda camada sobre as estratégias automatizadas. O SGR visa filtrar os gatilhos de compra das estratégias de forma a minimizar o risco da operação. A redução de risco é baseada em permitir operações de compra em uma região de compra próxima do valor mínimo diário previsto pelo modelo, e de forma análoga para as operações de venda. Espera-se que o SGR aumente a taxa de acerto das estratégias e a relação risco/ganho, contribuindo para o alcance de um retorno financeiro líquido positivo.

A seguir, serão apresentadas as comparações da execução das estratégias com e sem a aplicação do SGR para os cinco ativos selecionados (Tabelas 5.15 a 5.27). As estratégias que tiveram melhor desempenho com a aplicação do SGR estão com o fundo em verde, enquanto as estratégias que apresentaram desempenho melhor que o *baseline* primário (levando em consideração a alocação média das operações) estão em negrito.

Ademais, a fim de evidenciar o impacto do sistema de gestão de risco (SGR) sobre as estratégias executadas, também serão apresentadas duas análises de caso da aplicação do mesmo para cada ativo por meio de gráficos e matrizes dos *trades* realizados: o melhor e o pior resultado obtido com a utilização do SGR para cada ativo.

5.5.2.1 ABEV3

Em relação ao ativo ABEV3, no qual o modelo de predição apresentou menor intervalo de variação de erro de predição (aproximadamente $\pm 1\%$) em relação aos demais ativos, a Tabela 5.15 demonstra que apenas a estratégia RSI não se beneficiou do uso do SGR.

As estratégias *Act on opening* e MACD (Posicionado) apresentaram retorno líquido maior do que o *baseline* primário, sendo o retorno da primeira de 0,41% (superior ao *baseline* 0,24%, considerando alocação de 2% do capital) e da segunda de 1,52% (superior ao *baseline* 1,21%, considerando alocação de 10% do capital).

É interessante notar que houve uma redução drástica da quantidade de operações realizadas nas estratégias de cruzamento de média. No entanto, a taxa de acerto não melhorou com a utilização do SGR a ponto de tornar as estratégias lucrativas.

Quando analisado o retorno sobre a alocação média, verifica-se que as estratégias *Act on opening* e MACD (Posicionado) apresentaram os melhores resultados, 17,8% e

Tabela 5.15: ABEV3 - Comparação das estratégias automatizadas com e sem uso do SGR

ABEV3 Baseline Buy-and-hold (capital alocado): 0.24% (2% alocado)/1.21% (10% alocado)	Retorno Bruto		Retorno Líq.		Qtde op.		Taxa de acerto		Risco/Ganho		Alocação média	Retorno sobre alocação
	Sem SGR	SGR	Sem SGR	SGR	Sem SGR	SGR	Sem SGR	SGR	Sem SGR	SGR		
Buy low/Sell High	0%	0%	-0.04%	0%	29	6	34.5%	50%	0.76	0.82	2.0%	0.0%
Act on opening	0.15%	0.67%	-0.11%	0.41%	188	188	46.3%	58.5%	0.95	1.24	2.3%	17.8%
Cruzamento de média	1.77%	0.63%	-1.35%	-0.01%	2427	538	32.1%	33.5%	0.82	0.99	2.0%	-0.5%
Cruzamento de 2 médias	-0.37%	0.15%	-1.35%	-0.04%	766	155	34%	32.9%	0.7	0.95	2.0%	-2.0%
Cruzamento de 3 médias (C/ liquidação)	-0.13%	0.04%	-0.36%	-0.06%	187	84	34.8%	31%	0.7	0.76	2.0%	-3.0%
Cruzamento de 3 médias (Posicionado)	-0.18%	0.2%	-0.6%	0.1%	395	77	35.5%	36.4%	0.77	1.27	2.0%	5.0%
RSI	0.46%	-0.08%	0.29%	-0.24%	23	22	59.1%	61.9%	1.08	0.93	12.8%	-1.9%
MACD (C/ liquidação)	-0.21%	-0.08%	-0.52%	-0.2%	262	99	30.3%	33.7%	0.77	0.8	2.0%	-10.1%
MACD (Posicionado)	1.07%	2.05%	0.22%	1.52%	116	78	60.9%	62.3%	1.03	1.3	11.4%	13.3%

Fonte: Elaborada pelo autor (2022)

13,3%, respectivamente, desempenho melhor do que os 12% do *baseline* primário da estratégia *buy and hold*.

Análise do melhor caso - MACD (Posicionado)

Observa-se pela Tabela 5.16 que houve uma redução substancial de operações (116 para 78) para estratégia MACD (Posicionado) ao adotar o SGR, ao passo que o resultado líquido e resultado médio por operação apresentaram melhoria em relação à estratégia sem uso do SGR. A gestão de risco aplicada foi capaz de reduzir a quantidade de operações não lucrativas e o prejuízo médio delas. Apesar de também ter reduzido a quantidade de operações lucrativas, tanto de compra como venda, o resultado médio por operação apresentou melhoria em relação à estratégia sem SGR, refletindo em uma relação risco/ganho mais atrativa (1,06 frente a 1,3 sem uso do SGR).


As Figuras 5.5.2.1 e 5.5.2.2 ilustram os *trades* realizados pela estratégia MACD (Posicionado) sem o uso do SGR e com SGR, respectivamente. As cores azul e vermelho sinalizam se o resultado da operação foi positivo ou negativo.

Tabela 5.16: ABEV3 - Estratégia com melhor desempenho utilizando SGR - MACD (Posicionado)


ABEV3		Retorno da operação		Resultado por tipo de operação Sem SGR Com SGR
MACD (Posicionado)		Positivo Sem SGR Com SGR	Negativo Sem SGR Com SGR	
Tipo de Operação	COMPRA	38 26 operações		57 38 operações
	Resultado Líq.	R\$ 4503.72 R\$ 3513.26		R\$ 915.08 R\$ 1384.23
	Res. médio por op.	R\$ 118.51 R\$ 135.12		R\$ 16.05 R\$ 36.42
	VENDA	32 22 operações		59 40 operações
Resultado Líq.	R\$ 4057.39 R\$ 3052.06		R\$ -690.47 R\$ 140.47	
Res. médio por op.	R\$ 126.79 R\$ 138.73		R\$ -11.7 R\$ 3.51	
Resultado por retorno		70 48 operações		116 78 operações
Resultado Líq.		R\$ 8561.11 R\$ 6565.32		R\$ 224.61 R\$ 1524.71
Res. médio por op.		R\$ 122.3 R\$ 136.77		R\$ 1.93 R\$ 19.54

Fonte: Elaborada pelo autor (2022)

Análise do pior caso - RSI

Figura 5.8: ABEV3 - *Trades* realizados pela estratégia MACD (Posicionado) sem uso do SGR

Fonte: Elaborada pelo autor (2022)

Figura 5.9: ABEV3 - *Trades* realizados pela estratégia MACD (Posicionado) utilizando SGR

Fonte: Elaborada pelo autor (2022)

Ao analisar o desempenho da estratégia RSI com e sem uso do SGR, observa-se pela Tabela 5.17 que houve uma manutenção da quantidade de operações. Contudo, o resultado médio por operação deteriorou-se, principalmente, pela redução de lucro nas operações de compra e venda. Assim, embora tenha havido uma melhoria na taxa de acerto da estratégia (de 59,1% para 61,9%), a relação risco/ganho reduziu de 1,08 para 0,93.

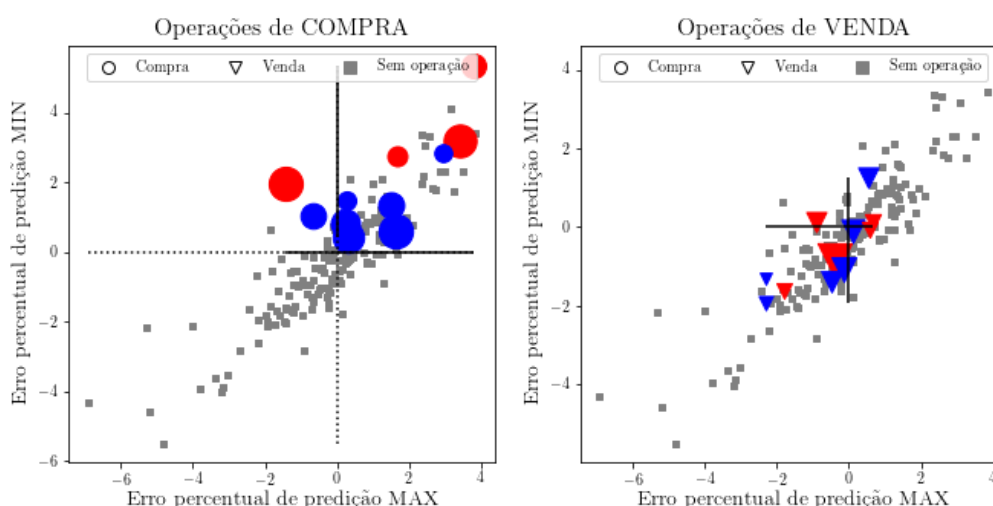
As Figuras 5.5.2.1 e 5.5.2.1 ilustram os *trades* realizados pela estratégia RSI sem o uso do SGR e com SGR, respectivamente. As cores azul e vermelho sinalizam se o resultado da operação foi positivo ou negativo.

Tabela 5.17: ABEV3 - Estratégia com pior desempenho utilizando SGR - RSI

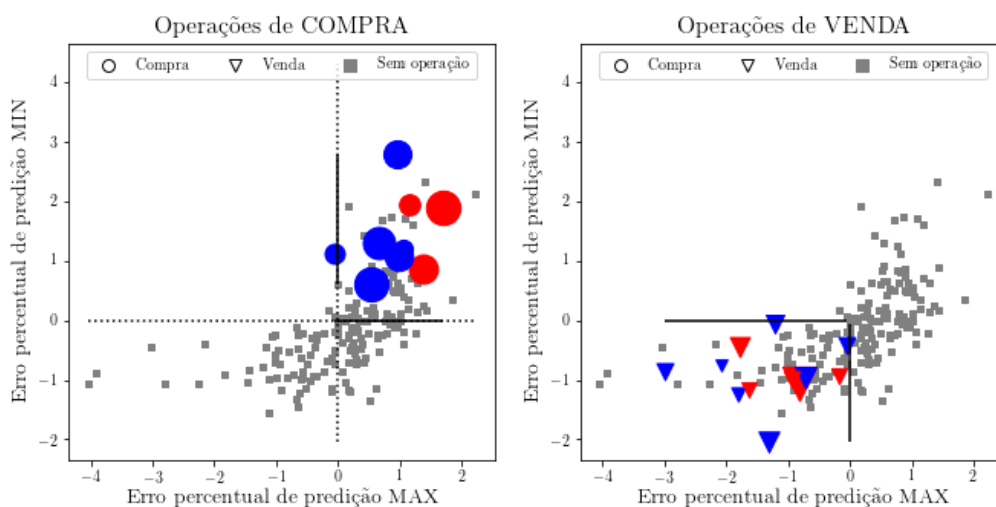
ABEV3 RSI		Retorno da operação		Resultado por tipo de operação Sem SGR Com SGR
		Positivo Sem SGR Com SGR	Negativo Sem SGR Com SGR	
Tipo de Operação	COMPRA	7 6 operações	4 3 operações	11 9 operações
	Resultado Líq.	R\$ 1273.47 R\$ 939.35	R\$ -843.73 R\$ -517.95	R\$ 429.74 R\$ 421.4
	Res. médio por op.	R\$ 181.92 R\$ 156.55	R\$ -210.93 R\$ -172.65	R\$ 39.06 R\$ 46.82
	VENDA	6 7 operações	6 6 operações	12 13 operações
Resultado Líq.	R\$ 2533.68 R\$ 2058.23	R\$ -2675.79 R\$ -2721.25	R\$ -142.11 R\$ -663.02	
Res. médio por op.	R\$ 422.28 R\$ 294.03	R\$ -445.96 R\$ -453.54	R\$ -11.84 R\$ -51	
Resultado por retorno		13 13 operações	10 9 operações	23 22 operações
Resultado Líq.		R\$ 3807.15 R\$ 2997.58	R\$ -3519.52 R\$ -3239.2	R\$ 287.63 R\$ -241.62
Res. médio por op.		R\$ 292.85 R\$ 230.58	R\$ -351.95 R\$ -359.91	R\$ 12.5 R\$ -10.98

Fonte: Elaborada pelo autor (2022)

Figura 5.10: ABEV3 - *Trades* realizados pela estratégia RSI sem uso do SGR



Fonte: Elaborada pelo autor (2022)

Figura 5.11: ABEV3 - *Trades* realizados pela estratégia RSI utilizando SGR

Fonte: Elaborada pelo autor (2022)

5.5.2.2 B3SA3

Em relação ao ativo B3SA3, no qual o modelo de previsão apresentou erro de previsão com intervalo de variação semelhante ao ativo ABEV3, aproximadamente $\pm 1,3\%$, a Tabela 5.18 demonstra que 3 estratégias não se beneficiaram com a aplicação do SGR, resultando em uma efetividade de 66%.

Tabela 5.18: B3SA3 - Comparação das estratégias automatizadas com e sem o uso do SGR

B3SA3 Baseline Buy-and-hold (capital alocado): 0.64% (2% alocado)/3.23% (10% alocado)	Retorno Bruto		Retorno Líquido		Qtde op.		Taxa de acerto		Risco/Ganho		Alocação média	Retorno sobre alocação
	Sem SGR	SGR	Sem SGR	SGR	Sem SGR	SGR	Sem SGR	SGR	Sem SGR	SGR		
Buy low/Sell High	-0.04%	0.01%	-0.06%	-0.02%	18	22	27.8%	18.2%	0.5	0.88	2.0%	-1.0%
Act on opening	0.47%	0.32%	0.24%	0.09%	188	188	54.3%	56.9%	1.1	1.04	2.0%	4.5%
Cruzamento de média	1.26%	0.31%	-1.6%	-0.15%	1873	390	32.6%	32.6%	0.85	0.9	2.0%	-7.6%
Cruzamento de 2 médias	0.72%	0.26%	-0.15%	0.13%	568	105	35.3%	38.5%	0.97	1.2	2.0%	6.6%
Cruzamento de 3 médias (C/ liquidação)	0.38%	0.04%	0.19%	0.02%	160	9	39.4%	33.3%	1.16	1.41	2.0%	1.0%
Cruzamento de 3 médias (Posicionado)	-1.61%	0.07%	-1.94%	0.05%	150	9	30.9%	44.4%	0.61	1.42	2.0%	2.5%
RSI	3.64%	4.28%	3.42%	4.11%	27	27	61.5%	73.1%	1.89	3.88	10.5%	39.2%
MACD (C/ liquidação)	1.41%	0.32%	1.16%	0.23%	208	78	44%	39%	1.57	1.26	2.0%	11.6%
MACD (Posicionado)	-0.21%	1.48%	-0.92%	1.18%	107	58	62.3%	66.7%	0.9	1.32	8.7%	13.6%

Fonte: Elaborada pelo autor (2022)

No geral, a adoção do SGR permitiu melhores relações de risco/ganho e taxas de acerto, acompanhadas de uma redução da quantidade de operações. A única estratégia que superou o *baseline* primário referente ao capital alocado foi RSI com retorno líquido de 4,11% e 10,5% de alocação média nas operações, e obteve 39,2% de retorno sobre o capital alocado nas operações, valor este superior à estratégia *buy-and-hold* que apresenta

32% de retorno sobre o capital alocado.

Nas estratégias em que não houve melhoria do resultado com aplicação do SGR observou-se deterioração da relação risco/ganho e nas estratégias *Act on opening* e Cruzamento de 3 médias (C/ liquidação) a manutenção da quantidade de operações, ao passo que na estratégia MACD (C/ liquidação) houve um decréscimo significativo da quantidade de operações (de 208 para 78).

Análise do melhor caso - RSI

A estratégia RSI para o ativo B3SA3, sem uso do SGR, gerou 27 operações conforme pode ser visto na Tabela 5.19. Destas operações, 11 resultaram em prejuízo, sendo este concentrado nas operações de venda.

A execução da estratégia RSI com aplicação do sistema de gestão de risco também realizou 27 operações apresentando 8 operações com prejuízo. O SGR foi capaz de reduzir o prejuízo médio das operações de R\$ 351,16 para R\$ 178,58 e tendo reduzido a quantidade de operações negativas, o prejuízo dessas operações reduziu-se de R\$ 3.862,76 para R\$ 1.428,71.

Embora o SGR também tenha reduzido o resultado médio das operações lucrativas, tanto de compra quanto de venda, o balanço final foi favorável ao uso do SGR, pois aumentou o lucro líquido de 3,49% para 4,11%. Em termos de retorno sobre o capital alocado, a estratégia RSI com uso do SGR apresentou retorno de 39,2%.

As Figuras 5.5.2.2 e 5.5.2.3 ilustram os *trades* realizados pela estratégia RSI sem o uso do SGR e com SGR, respectivamente. Percebe-se qualitativamente por meio desses gráficos a melhoria na qualidade das operações.

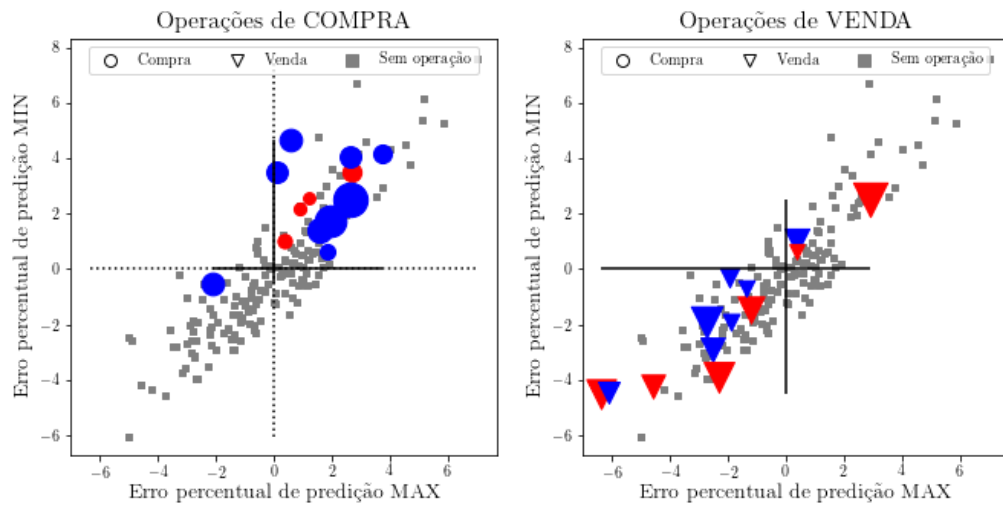
Tabela 5.19: B3SA3 - Estratégia com melhor desempenho utilizando SGR - RSI

B3SA3 RSI		Retorno da operação		Resultado por tipo de operação Sem SGR Com SGR	
		Positivo Sem SGR Com SGR	Negativo Sem SGR Com SGR		
Tipo de Operação	COMPRA	9 9 operações		4 4 operações	
	Resultado Líq.	R\$ 4810.73 R\$ 3505.18		R\$ -446.7 R\$ -348.47	
	Res. médio por op.	R\$ 534.52 R\$ 389.46		R\$ -111.67 R\$ -87.11	
	VENDA	7 10 operações		7 4 operações	
Resultado Líq.	R\$ 2471.41 R\$ 2035.41		R\$ -3416.06 R\$ -1080.24		
Res. médio por op.	R\$ 353.05 R\$ 203.54		R\$ -488 R\$ -270.06		
Resultado por retorno		16 19 operações		11 8 operações	
Resultado Líq.		R\$ 7282.14 R\$ 5540.59		R\$ -3862.76 R\$ -1428.71	
Res. médio por op.		R\$ 455.13 R\$ 291.61		R\$ -351.16 R\$ -178.58	
				27 27 operações	
				R\$ 3419.38 R\$ 4111.88	
				R\$ 126.64 R\$ 152.29	

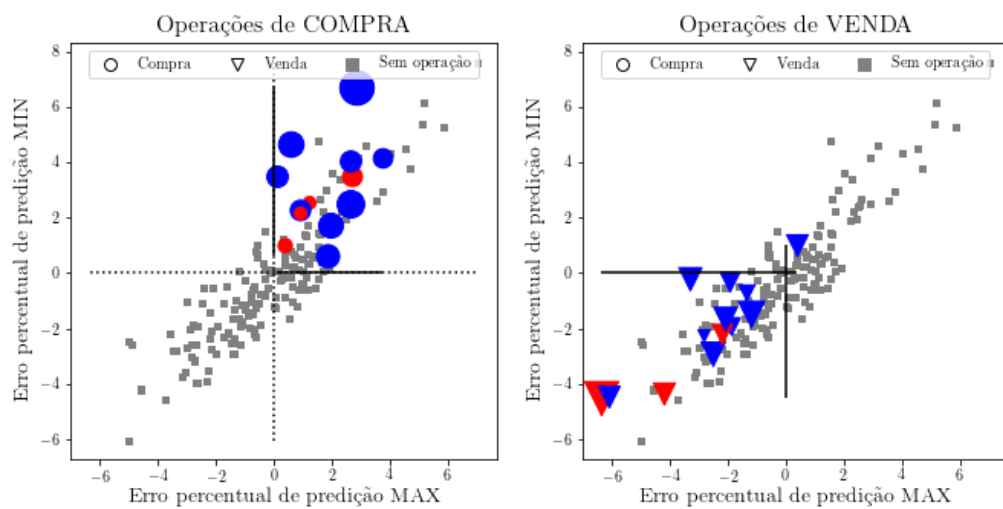
Fonte: Elaborada pelo autor (2022)

Análise do pior caso - Cruzamento de média

Ao analisar o desempenho da estratégia de cruzamento de média com e sem uso do SGR, observa-se pela Tabela 5.20 que o resultado com uso do SGR (prejuízo de 0,15%) foi melhor que o resultado sem o uso do SGR (prejuízo de 1,59%). Isto foi devido em

Figura 5.12: B3SA3 - *Trades* realizados pela estratégia RSI sem uso do SGR

Fonte: Elaborada pelo autor (2022)

Figura 5.13: B3SA3 - *Trades* realizados pela estratégia RSI utilizando SGR

Fonte: Elaborada pelo autor (2022)

grande parte à drástica redução da quantidade de operações, principalmente de operações não lucrativas, que na estratégia sem uso do SGR representava aproximadamente 2/3 das operações (No total de 1264 operações). Apesar da proporção de operações não lucrativas ter se mantido na estratégia com SGR, houve uma drástica redução do prejuízo de R\$ 10.333,07 para R\$ 1.531,40.

Contudo, o uso do SGR também reduziu a quantidade de operações lucrativas e o resultado médio por operação deteriorou-se de R\$ 14,34 para R\$ 10,86. No balanço final, houve uma melhora do resultado da estratégia devido à melhoria da relação risco/ganho de 0,85 para 0,9, mas que não foi suficiente para tornar o retorno da estratégia lucrativo, dada a baixa taxa de acerto 32,6%.

As Figuras 5.5.2.2 e 5.5.2.2 ilustram os *trades* realizados pela estratégia RSI sem o uso do SGR e com SGR, respectivamente. É nítida a redução da quantidade de operações, bem como a predominância de operações de venda quando o erro de predição do valor máximo é negativo e de compra quando o erro de predição do valor mínimo do ativo é positivo, o que certamente não contribuiu para melhorar a taxa de acerto da estratégia.

Tabela 5.20: B3SA3 - Estratégia com pior desempenho utilizando SGR - Cruzamento de média


B3SA3 Cruzamento de média		Retorno da operação		Resultado por tipo de operação Sem SGR Com SGR
		Positivo Sem SGR Com SGR	Negativo Sem SGR Com SGR	
Tipo de Operação	COMPRA	313 60 operações	623 103 operações	936 163 operações
	Resultado Líq. Res. médio por op.	R\$ 4741.32 R\$ 749.85 R\$ 15.14 R\$ 12.49	R\$ -5208.25 R\$ -619.08 R\$ -8.35 R\$ -6.01	R\$ -466.93 R\$ 130.77 R\$ -0.49 R\$ 0.8
Operação	VENDA	296 67 operações	641 160 operações	937 227 operações
	Resultado Líq. Res. médio por op.	R\$ 3992.26 R\$ 630.52 R\$ 13.48 R\$ 9.41	R\$ -5124.82 R\$ -912.32 R\$ -7.99 R\$ -5.7	R\$ -1132.56 R\$ -281.8 R\$ -1.2 R\$ -1.24
Resultado por retorno		609 127 operações	1264 263 operações	1873 390 operações
Resultado Líq. Res. médio por op.		R\$ 8733.58 R\$ 1380.37 R\$ 14.34 R\$ 10.86	R\$ -10333.07 R\$ -1531.4 R\$ -8.17 R\$ -5.82	R\$ -1599.49 R\$ -151.03 R\$ -0.85 R\$ -0.38

Fonte: Elaborada pelo autor (2022)

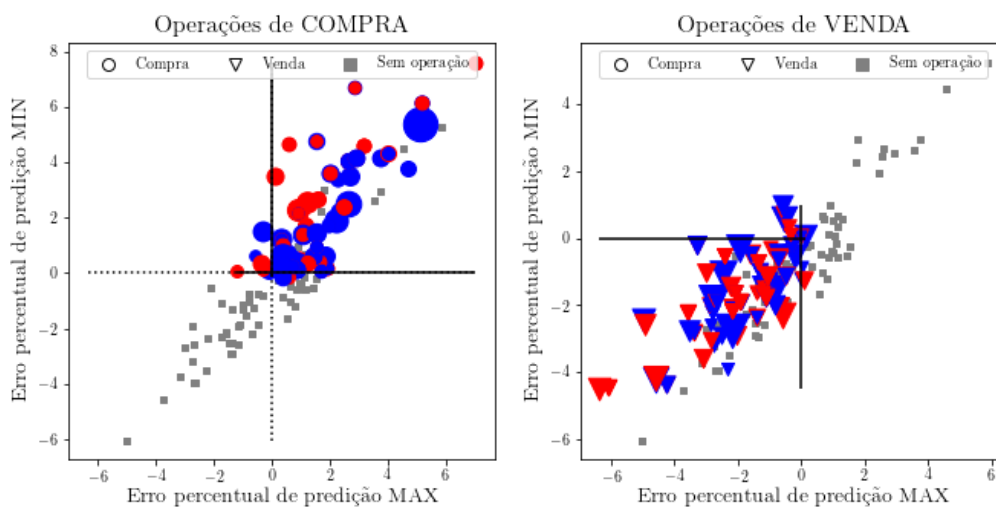
5.5.2.3 ITUB4

Para o ativo ITUB4, a Tabela 5.21 permite verificar uma efetividade de 77% na melhoria do desempenho das estratégias (7 de 9 estratégias apresentaram melhor resultado com o SGR).

Conforme esperado, as estratégias *Buy low/Sell High* e *Act on opening* mostraram-se menos sensíveis à aplicação do SGR pois o único impacto do SGR nessas estratégias é a aplicação de *stoploss* e que resultou na redução da taxa de acerto e risco/ganho.

Figura 5.14: B3SA3 - *Trades* realizados pela estratégia de Cruzamento de média sem uso do SGR

Fonte: Elaborada pelo autor (2022)

Figura 5.15: B3SA3 - *Trades* realizados pela estratégia de Cruzamento de média utilizando SGR

Fonte: Elaborada pelo autor (2022)

As demais estratégias apresentaram melhoria na taxa de acerto e relação risco/ganho, embora as estratégias de cruzamento de média ainda tenha apresentado retorno líquido próximo de zero. A estratégia que apresentou melhor desempenho foi RSI, na qual a aplicação do SGR foi capaz de melhorar a relação risco/ganho de 1,39 para 1,64, o que resultou na melhoria do retorno líquido de 0,85% para 1,14%, resultado acima do *baseline* primário (1,13%) quando comparado com o mesmo volume de capital alocado (10%).

Análise do melhor caso - RSI

A estratégia RSI para o ativo ITUB4, sem uso do SGR, gerou 21 operações conforme pode ser visto na Tabela 5.22. Destas operações, 9 resultaram em prejuízo, sendo este concentrado nas operações de venda (6 operações).

A execução da estratégia RSI com aplicação do sistema de gestão de risco realizou 20 operações apresentando 8 operações com prejuízo, com leve redução do prejuízo médio das operações de R\$ 241,13 para R\$ 224,34 e portanto, o prejuízo dessas operações reduziu-se de R\$ 2.170,20 para R\$ 1.794,76.

Embora o SGR também tenha reduzido levemente o resultado médio das operações lucrativas (reduziu nas operações de venda e aumentou nas operações de compra), o consolidado das operações lucrativas bem próximo da estratégia sem uso do SGR. Em termos de retorno sobre o capital alocado, a estratégia RSI com uso do SGR apresentou retorno de 10,9%, valor este compatível com a estratégia *buy-and-hold* (11,0%).

As Figuras 5.22 e 5.5.2.3 ilustram os *trades* realizados pela estratégia RSI sem o uso do SGR e com SGR, respectivamente.

Análise do pior caso - *Act on opening*

Ao analisar o desempenho da estratégia *act on opening* com e sem uso do SGR, observa-se pela Tabela 5.23 um leve aumento do prejuízo da estratégia, passando de 0,39% para 0,66%.

O impacto do SGR nessa estratégia é de aplicar *stoploss* nas operações e como nessa estratégia a quantidade de operações é a mesma com e sem o uso do SGR, verifica-se apenas variações na distribuição de operações lucrativas e com prejuízo. No geral, observa-se que o uso do SGR deteriorou o resultado médio nas operações que geravam lucro e manteve aproximadamente constante o resultado médio das operações não lucrativas.

As Figuras 5.5.2.3 e 5.5.2.3 ilustram os *trades* realizados pela estratégia RSI sem o uso do SGR e com SGR, respectivamente.

5.5.2.4 PETR4

A efetividade da aplicação do SGR para o ativo PETR4 foi de 55% sobre as estratégias testadas. Houve uma melhoria no retorno líquido de 5 estratégias entre as 9 implementadas, conforme apresenta a Tabela 5.24.

Pequenas melhorias na relação de risco/ganho e taxa de acerto e redução expressiva da quantidade de operações melhoraram o resultado das estratégias baseadas em cruzamento de médias, mas não ao ponto de obter um retorno líquido positivo.

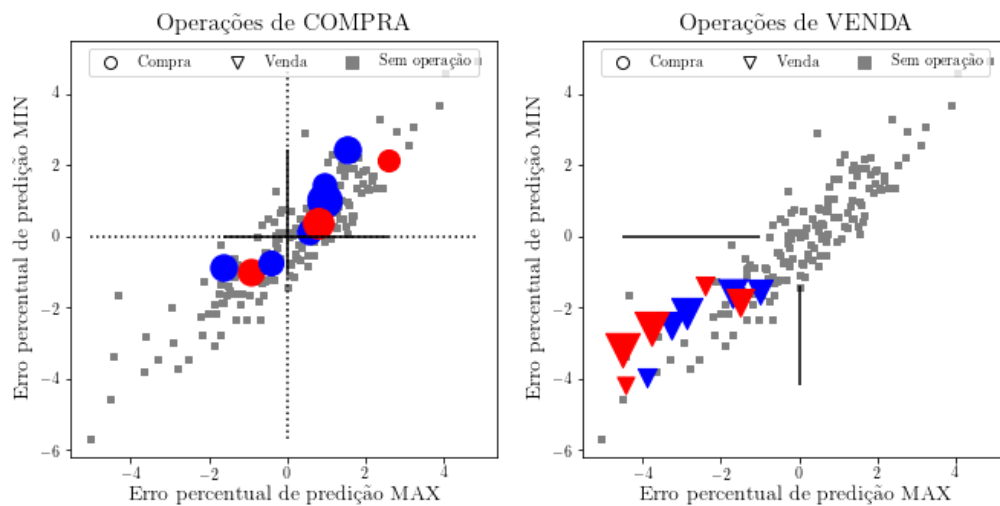
Nas estratégias onde o SGR não foi efetivo, houve redução da relação risco/ganho

Tabela 5.21: ITUB4 - Comparação das estratégias automatizadas com e sem uso do SGR

ITUB4 Baseline Buy-and-hold (capital alocado): 0.22% (2% alocado)/1.13% (10% alocado)	Retorno Bruto		Retorno Líquido		Qtde op.		Taxa de acerto		Risco/Ganho		Alocação média	Retorno sobre alocação
	Sem SGR	SGR	Sem SGR	SGR	Sem SGR	SGR	Sem SGR	SGR	Sem SGR	SGR		
Buy low/Sell High	0.04%	-0.06%	0.01%	-0.09%	25	27	36%	18.5%	1.09	0.41	2.0%	-4.5%
Act on opening	-0.16%	-0.44%	-0.39%	-0.66%	188	188	45.2%	49.5%	0.82	0.68	2.0%	-33.3%
Cruzamento de média	1.33%	0.29%	-1.85%	-0.35%	2562	540	31.9%	31.9%	0.78	0.77	2.0%	-17.7%
Cruzamento de 2 médias	-0.1%	0.16%	-0.85%	0.01%	613	122	34.5%	39.3%	0.8	1.02	2.0%	0.5%
Cruzamento de 3 médias (C/ liquidação)	-0.67%	0%	-0.9%	-0.02%	193	15	28%	26.7%	0.44	0.8	2.0%	-1.0%
Cruzamento de 3 médias (Posicionado)	-0.25%	-0.04%	-0.53%	-0.06%	152	14	40.4%	42.9%	0.84	0.69	2.0%	-3.0%
RSI	0.98%	1.27%	0.85%	1.14%	21	20	60%	60%	1.39	1.64	10.5%	10.9%
MACD (C/ liquidação)	-0.25%	0.04%	-0.54%	-0.08%	246	99	33.5%	37.4%	0.77	0.91	2.0%	-4.0%
MACD (Posicionado)	0.54%	0.85%	-0.1%	0.47%	121	73	62.5%	64.4%	0.99	1.12	8.5%	5.5%

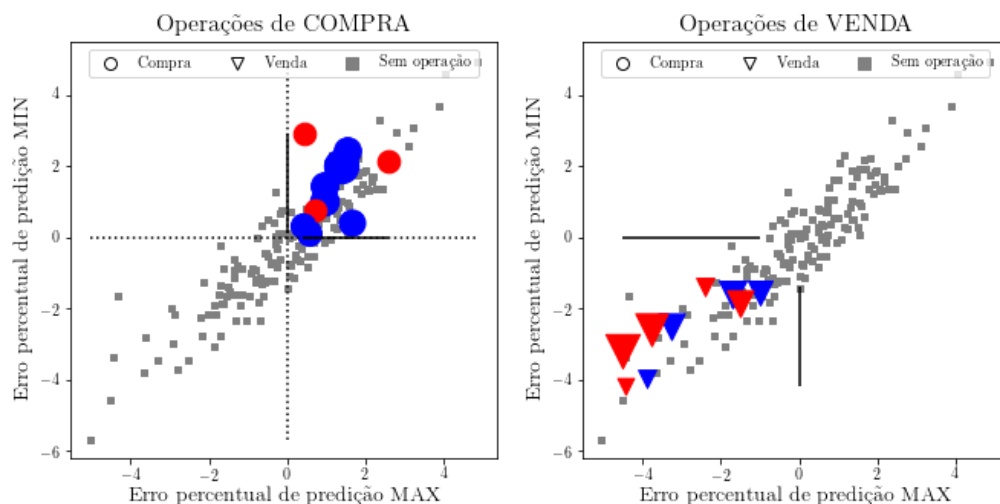
Fonte: Elaborada pelo autor (2022)

Figura 5.16: ITUB4 - *Trades* realizados pela estratégia RSI sem uso do SGR



Fonte: Elaborada pelo autor (2022)

Figura 5.17: ITUB4 - *Trades* realizados pela estratégia RSI utilizando SGR



Fonte: Elaborada pelo autor (2022)

Tabela 5.22: ITUB4 - Estratégia com melhor desempenho utilizando SGR - RSI


ITUB4 RSI		Retorno da operação		Resultado por tipo de operação Sem SGR Com SGR
		Positivo Sem SGR Com SGR	Negativo Sem SGR Com SGR	
Tipo de Operação	COMPRA	7 8 operações	3 3 operações	10 11 operações
	Resultado Líq. Res. médio por op.	R\$ 1754.04 R\$ 2091.06 R\$ 250.57 R\$ 261.38	R\$ -806.17 R\$ -482.02 R\$ -268.72 R\$ -160.67	R\$ 947.87 R\$ 1609.04 R\$ 94.78 R\$ 146.27
Tipo de Operação	VENDA	5 4 operações	6 5 operações	11 9 operações
	Resultado Líq. Res. médio por op.	R\$ 1266.63 R\$ 844.93 R\$ 253.32 R\$ 211.23	R\$ -1364.03 R\$ -1312.74 R\$ -227.33 R\$ -262.54	R\$ -97.39 R\$ -467.81 R\$ -8.85 R\$ -51.97
Resultado por retorno		12 12 operações	9 8 operações	21 20 operações
Resultado Líq. Res. médio por op.		R\$ 3020.67 R\$ 2935.99 R\$ 251.72 R\$ 244.66	R\$ -2170.2 R\$ -1794.76 R\$ -241.13 R\$ -224.34	R\$ 850.47 R\$ 1141.23 R\$ 40.49 R\$ 57.06

Fonte: Elaborada pelo autor (2022)

Tabela 5.23: ITUB4 - Estratégia com pior desempenho utilizando SGR - Cruzamento de média

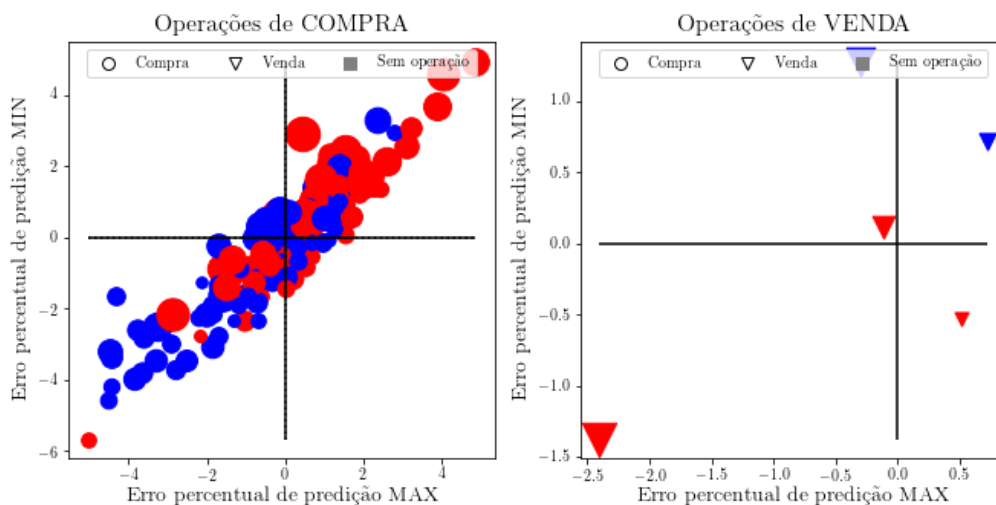
ITUB4 Act on opening		Retorno da operação		Resultado por tipo de operação Sem SGR Com SGR
		Positivo Sem SGR Com SGR	Negativo Sem SGR Com SGR	
Tipo de Operação	COMPRA	83 91 operações	100 92 operações	183 183 operações
	Resultado Líq. Res. médio por op.	R\$ 1748.83 R\$ 1340.55 R\$ 21.07 R\$ 14.73	R\$ -2125.48 R\$ -1974.45 R\$ -21.25 R\$ -21.46	R\$ -376.65 R\$ -633.9 R\$ -2.05 R\$ -3.46
Tipo de Operação	VENDA	2 2 operações	3 3 operações	5 5 operações
	Resultado Líq. Res. médio por op.	R\$ 53.79 R\$ 36.58 R\$ 26.89 R\$ 18.29	R\$ -63.42 R\$ -63.42 R\$ -21.14 R\$ -21.14	R\$ -9.63 R\$ -26.84 R\$ -1.92 R\$ -5.36
Resultado por retorno		85 93 operações	103 95 operações	188 188 operações
Resultado Líq. Res. médio por op.		R\$ 1802.62 R\$ 1377.13 R\$ 21.2 R\$ 14.8	R\$ -2188.9 R\$ -2037.87 R\$ -21.25 R\$ -21.45	R\$ -386.28 R\$ -660.74 R\$ -2.05 R\$ -3.51

Fonte: Elaborada pelo autor (2022)

Figura 5.18: ITUB4 - *Trades* realizados pela estratégia *Act on opening* sem uso do SGR

Fonte: Elaborada pelo autor (2022)

e redução da quantidade de operações (exceto na estratégia *Act on opening* que realiza a mesma quantidade de operações com ou sem SGR).

Figura 5.19: ITUB4 - *Trades* realizados pela estratégia *Act on opening* utilizando SGR

Fonte: Elaborada pelo autor (2022)

Tabela 5.24: PETR4 - Comparação das estratégias automatizadas com e sem uso do SGR

PETR4 Baseline Buy-and-hold (capital alocado): 0.2% (2% alocado)/1.01% (10% alocado)	Retorno Bruto		Retorno Líquido		Qtde op.		Taxa de acerto		Risco/Ganho		Alocação média	Retorno sobre alocação
	Sem SGR	SGR	Sem SGR	SGR	Sem SGR	SGR	Sem SGR	SGR	Sem SGR	SGR		
Buy low/Sell High	0.01%	-0.03%	-0.01%	-0.05%	16	17	31.2%	17.6%	0.91	0.54	2.0%	-2.5%
Act on opening	-0.46%	-0.52%	-0.68%	-0.74%	188	188	43.6%	47.3%	0.71	0.67	2.0%	-37.4%
Cruzamento de média	1%	0.25%	-1.26%	-0.2%	1926	379	32.2%	34.6%	0.81	0.84	2.0%	-10.1%
Cruzamento de 2 médias	1.24%	0.27%	-0.41%	-0.06%	1414	279	34.3%	34.8%	0.92	0.94	2.0%	-3.0%
Cruzamento de 3 médias (C/ liquidação)	0.09%	0.01%	-0.12%	0%	176	11	34.9%	36.4%	0.91	0.95	2.0%	0.0%
Cruzamento de 3 médias (Posicionado)	-0.24%	-0.02%	-0.48%	-0.03%	154	11	32%	36.4%	0.82	0.74	2.0%	-1.5%
RSI	-1.36%	-0.33%	-1.6%	-0.51%	41	30	55%	58.6%	0.72	0.87	10.2%	-5.0%
MACD (C/ liquidação)	0.65%	0.14%	0.4%	0.05%	217	78	38.4%	38.5%	1.19	1.06	2.0%	2.5%
MACD (Posicionado)	3.13%	1.26%	2.78%	1.1%	105	47	66.3%	65.2%	1.87	1.57	5.7%	19.2%

Fonte: Elaborada pelo autor (2022)

A estratégia que apresentou melhor resultado foi MACD (Posicionado) sem aplicação de SGR (2,78% de retorno líquido), resultado muito superior ao *baseline* primário de 0,51% (para 5% do capital alocado). Embora o SGR tenha deteriorado o desempenho da estratégia, reduzindo a quantidade de operações pela metade e o risco/ganho de 1,87 para 1,57%, o retorno líquido foi de 1,1%, resultado ainda superior ao *baseline* primário. O retorno sobre o capital aplicado na estratégia MACD (Posicionado) com uso do SGR foi de 19,2%, resultado que representa quase o dobro do retorno sobre capital investido do *baseline* primário da estratégia *buy-and-hold* (10%).

Análise do melhor caso - MACD (Posicionado)

Observa-se pela Tabela 5.25 que houve uma redução substancial de operações (105 para 47) para estratégia MACD (Posicionado) ao adotar o SGR, bem como uma redução do resultado líquido (R\$ 2.776,89 -; R\$ 1.101,36) e resultado médio por operação (R\$ 26,44 -; R\$ 23,43).

O maior impacto da gestão de risco aplicada foi na redução do resultado líquido de operações lucrativas. Embora o resultado médio por operação tenha melhorado tanto para operações de compra (de R\$ 92,64 para R\$ 100,67) quanto de venda (de R\$ 80,08 para R\$ 101,27), a redução da quantidade de operações lucrativas reduziu bastante o lucro consolidado. A redução do prejuízo consolidado (R\$ 3.188,40 para R\$ 1.928,47) não foi suficiente para repor as perdas de lucro das operações lucrativas que deixaram de ser executadas, refletindo, portanto, na redução da relação risco/ganho de 1,87 para 1,57.

As Figuras 5.5.2.4 e 5.5.2.4 ilustram os *trades* realizados pela estratégia MACD (Posicionado) sem o uso do SGR e com SGR, respectivamente. As cores azul e vermelho sinalizam se o resultado da operação foi positivo ou negativo.

Tabela 5.25: PETR4 - Estratégia com melhor desempenho utilizando SGR - MACD (Posicionado)

PETR4 MACD (Posicionado)		Retorno da operação		Resultado por tipo de operação Sem SGR Com SGR
		Positivo Sem SGR Com SGR	Negativo Sem SGR Com SGR	
Tipo de Operação	COMPRA	35 14 operações	17 8 operações	52 22 operações
	Resultado Líq. Res. médio por op.	R\$ 3242.52 R\$ 1409.46 R\$ 92.64 R\$ 100.67	R\$ -1552.53 R\$ -948.04 R\$ -91.32 R\$ -118.5	R\$ 1689.99 R\$ 461.42 R\$ 32.49 R\$ 20.97
Operação	VENDA	34 16 operações	19 9 operações	53 25 operações
	Resultado Líq. Res. médio por op.	R\$ 2722.77 R\$ 1620.37 R\$ 80.08 R\$ 101.27	R\$ -1635.87 R\$ -980.43 R\$ -86.09 R\$ -108.93	R\$ 1086.9 R\$ 639.94 R\$ 20.5 R\$ 25.59
Resultado por retorno		69 30 operações	36 17 operações	105 47 operações
Resultado Líq.		R\$ 5965.29 R\$ 3029.83	R\$ -3188.4 R\$ -1928.47	R\$ 2776.89 R\$ 1101.36
Res. médio por op.		R\$ 86.45 R\$ 100.99	R\$ -88.56 R\$ -113.43	R\$ 26.44 R\$ 23.43

Fonte: Elaborada pelo autor (2022)


Análise do pior caso - *Act on opening*

Ao analisar o desempenho da estratégia *act on opening* com e sem uso do SGR, observa-se pela Tabela 5.26 um leve aumento do prejuízo da estratégia, passando de 0,68% para 0,74%.


Tabela 5.26: PETR4 - Estratégia com pior desempenho utilizando SGR - *Act on opening*

PETR4 Act on opening		Retorno da operação		Resultado por tipo de operação Sem SGR Com SGR
		Positivo Sem SGR Com SGR	Negativo Sem SGR Com SGR	
Tipo de Operação	COMPRA	79 86 operações	106 99 operações	185 185 operações
	Resultado Líq. Res. médio por op.	R\$ 1619.64 R\$ 1457.68 R\$ 20.5 R\$ 16.94	R\$ -2354.16 R\$ -2241.41 R\$ -22.2 R\$ -22.64	R\$ -734.51 R\$ -783.73 R\$ -3.97 R\$ -4.23
Operação	VENDA	3 3 operações	0 0 operações	3 3 operações
	Resultado Líq. Res. médio por op.	R\$ 49.71 R\$ 42.71 R\$ 16.57 R\$ 14.23	R\$ 0 R\$ 0 -	R\$ 49.71 R\$ 42.71 R\$ 16.57 R\$ 14.23
Resultado por retorno		82 89 operações	106 99 operações	188 188 operações
Resultado Líq.		R\$ 1669.35 R\$ 1500.39	R\$ -2354.16 R\$ -2241.41	R\$ -684.8 R\$ -741.02
Res. médio por op.		R\$ 20.35 R\$ 16.85	R\$ -22.2 R\$ -22.64	R\$ -3.64 R\$ -3.94

Fonte: Elaborada pelo autor (2022)

Figura 5.20: PETR4 - *Trades* realizados pela estratégia MACD (Posicionado) sem uso do SGR

Fonte: Elaborada pelo autor (2022)


Figura 5.21: PETR4 - *Trades* realizados pela estratégia MACD (Posicionado) utilizando SGR

Fonte: Elaborada pelo autor (2022)

Da mesma forma como foi explanado para o ativo ITUB4, o impacto do SGR na estratégia *act on opening* é de aplicar *stoploss* nas operações e como nessa estratégia a quantidade de operações é a mesma com e sem o uso do SGR, verifica-se apenas variações na distribuição de operações lucrativas e com prejuízo. No geral, observa-se que o uso do SGR deteriorou o resultado médio nas operações que geravam lucro e manteve aproximadamente constante o resultado médio das operações não lucrativas.

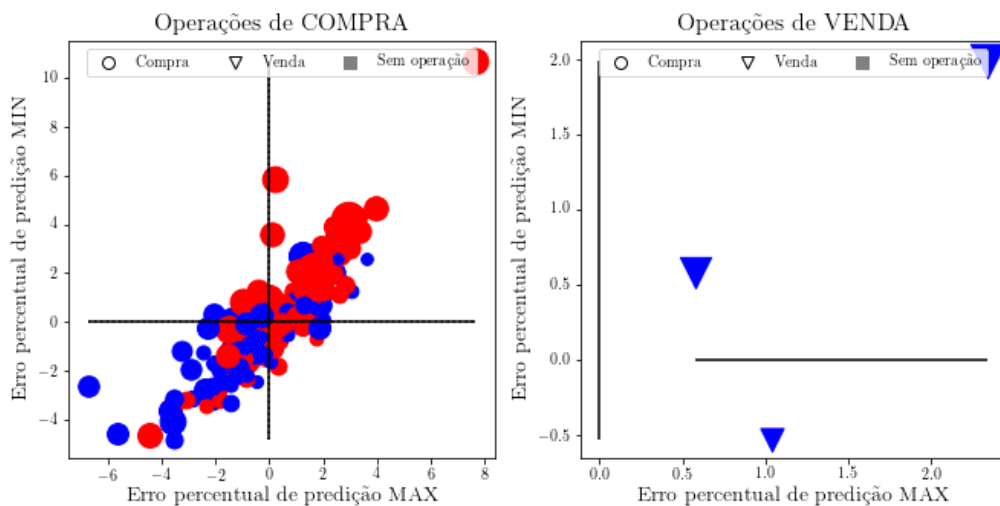
As Figuras 5.5.2.4 e 5.5.2.4 ilustram os *trades* realizados pela estratégia RSI sem o uso do SGR e com SGR, respectivamente. As cores azul e vermelho sinalizam se o resultado da operação foi positivo ou negativo.

Figura 5.22: PETR4 - *Trades* realizados pela estratégia *Act on opening* sem uso do SGR



Fonte: Elaborada pelo autor (2022)

Figura 5.23: PETR4 - *Trades* realizados pela estratégia *Act on opening* utilizando SGR



Fonte: Elaborada pelo autor (2022)

5.5.2.5 USIM5

O modelo de predição do ativo USIM5 foi o que apresentou maior variação de erro de predição (aproximadamente $\pm 2\%$) e, por consequência, a utilização do SGR apresentou a menor efetividade, 33% (melhoria em apenas 3 estratégias entre as 9 testadas), conforme pode ser visto na Tabela 5.27.

Ainda assim, a melhoria que o SGR proporcionou nessas três estratégias não foi capaz de reverter o retorno líquido negativo das estratégias sem a aplicação de SGR. Não obstante, é necessário observar também que o retorno financeiro do *baseline* primário é negativo (-0,14%).

Observou-se que reduções na relação risco/ganho, em alguns casos também acompanhada da redução de taxa de acerto, contribuíram para deteriorar o retorno líquido das estratégias. Duas estratégias apresentaram melhor resultado que o *baseline* primário após a aplicação do SGR: *Buy low/Sell High* e Cruzamento de médias (posicionado). A estratégia RSI sem aplicação do SGR foi a que apresentou melhor retorno líquido (1,07%), resultado bem superior ao *baseline* primário. A aplicação do SGR na estratégia RSI impactou negativamente a relação risco/ganho, que passou de 1,51 para 0,87, e embora tenha havido uma melhoria na taxa de acerto (de 58,8% para 66,7%), o aumento da quantidade de operações (de 18 para 25) resultou em um resultado líquido de -0,6%.

Análise do melhor caso - *Buy low/Sell high*

Observa-se pela Tabela 5.28 que a aplicação do SGR sobre a estratégia *Buy low/Sell high*, que impacta basicamente por meio da adoção de stoploss, manteve o resultado praticamente inalterado da estratégia sem SGR.

Observa-se um aumento do número de operações de 22 para 26 e uma melhoria na qualidade das operações de venda que resultaram em lucro, elevando o resultado médio de R\$ 16,69 para R\$ 24,19. No entanto, o aumento da quantidade de operações concentrou-se basicamente no acréscimo de operações de venda que resultaram em prejuízo, anulando os ganhos das operações lucrativas de venda.

As Figuras 5.5.2.5 e 5.5.2.5 ilustram os *trades* realizados pela estratégia MACD (Posicionado) sem o uso do SGR e com SGR, respectivamente. As cores azul e vermelho sinalizam se o resultado da operação foi positivo ou negativo.


Análise do pior caso - MACD (Posicionado)

Ao analisar o desempenho da estratégia MACD (Posicionado) com e sem uso do SGR, observa-se pela Tabela 5.29 uma drástica redução da quantidade de operações (de 112 para 60).


Tabela 5.27: USIM5 - Comparação das estratégias automatizadas com e sem uso do SGR

USIM5	Retorno Bruto		Retorno Líquido		Qtde op.		Taxa de acerto		Risco/Ganho		Alocação média	Retorno sobre alocação
	Sem SGR	SGR	Sem SGR	SGR	Sem SGR	SGR	Sem SGR	SGR	Sem SGR	SGR		
Baseline Buy-and-hold (capital alocado): -0.14% (2% alocado)/-0.71% (10% alocado)												
Buy low/Sell High	-0.04%	-0.04%	-0.07%	-0.07%	22	26	27.3%	19.2%	0.56	0.63	2.0%	-3.5%
Act on opening	0.26%	-0.23%	-0.21%	-0.69%	188	188	52.7%	56.4%	0.97	0.88	4.1%	-16.7%
Cruzamento de média	0.96%	-0.03%	-0.91%	-0.53%	1903	414	35.1%	31.6%	0.86	0.73	2.0%	-26.6%
Cruzamento de 2 médias	-0.69%	-0.12%	-1.1%	-0.2%	418	72	35.7%	31.9%	0.71	0.71	2.0%	-10.1%
Cruzamento de 3 médias (C/ liquidação)	0.37%	-0.13%	0.18%	-0.15%	154	14	35.1%	14.3%	1.13	0.29	2.0%	-7.5%
Cruz. de 3 médias (Posicionado)	-0.06%	-0.1%	-0.2%	-0.11%	135	13	34.3%	30.8%	0.9	0.52	2.0%	-5.5%
RSI	1.14%	-0.49%	1.07%	-0.6%	18	25	58.8%	66.7%	1.51	0.87	8.0%	-7.5%
MACD (C/ liquidação)	0.38%	-0.25%	0.08%	-0.36%	255	93	37.4%	32.3%	1.03	0.72	2.0%	-18.1%
MACD (Posicionado)	-0.6%	-1.17%	-0.81%	-1.31%	112	60	62.2%	58.3%	0.78	0.59	3.8%	-34.7%

Fonte: Elaborada pelo autor (2022)

Figura 5.24: USIM5 - *Trades* realizados pela estratégia *Buy low/Sell high* sem uso do SGR

Fonte: Elaborada pelo autor (2022)

Figura 5.25: USIM5 - *Trades* realizados pela estratégia *Buy low/Sell high* utilizando SGR

Fonte: Elaborada pelo autor (2022)

Tabela 5.28: USIM5 - Estratégia com melhor desempenho utilizando SGR - *Buy low/Sell high*

USIM5 Buy low/Sell high		Retorno da operação		Resultado por tipo de operação Sem SGR Com SGR
		Positivo Sem SGR Com SGR	Negativo Sem SGR Com SGR	
Tipo de Operação	COMPRA	1 0 operações	8 9 operações	9 9 operações
	Resultado Líq. Res. médio por op.	R\$ 6.54 R\$ 0 R\$ 6.54 R\$ -	R\$ -90.77 R\$ -92.06 R\$ -11.34 R\$ -10.22	R\$ -84.23 R\$ -92.06 R\$ -9.35 R\$ -10.22
Operação	VENDA	5 5 operações	8 12 operações	13 17 operações
	Resultado Líq. Res. médio por op.	R\$ 83.45 R\$ 120.95 R\$ 16.69 R\$ 24.19	R\$ -69.49 R\$ -98.73 R\$ -8.68 R\$ -8.22	R\$ 13.96 R\$ 22.22 R\$ 1.07 R\$ 1.3
Resultado por retorno		6 5 operações	16 21 operações	22 26 operações
Resultado Líq. Res. médio por op.		R\$ 89.99 R\$ 120.95 R\$ 14.99 R\$ 24.19	R\$ -160.26 R\$ -190.79 R\$ -10.01 R\$ -9.08	R\$ -70.27 R\$ -69.84 R\$ -3.19 R\$ -2.68

Fonte: Elaborada pelo autor (2022)

Tabela 5.29: USIM5 - Estratégia com pior desempenho utilizando SGR - MACD (Posicionado)

USIM5 MACD (Posicionado)		Retorno da operação		Resultado por tipo de operação Sem SGR Com SGR
		Positivo Sem SGR Com SGR	Negativo Sem SGR Com SGR	
Tipo de Operação	COMPRA	34 20 operações	22 13 operações	56 33 operações
	Resultado Líq. Res. médio por op.	R\$ 1468.35 R\$ 1093.55 R\$ 43.18 R\$ 54.67	R\$ -1945.14 R\$ -1405.12 R\$ -88.41 R\$ -108.08	R\$ -476.79 R\$ -311.57 R\$ -8.51 R\$ -9.44
Operação	VENDA	35 15 operações	21 12 operações	56 27 operações
	Resultado Líq. Res. médio por op.	R\$ 1345.87 R\$ 756.84 R\$ 38.45 R\$ 50.45	R\$ -1681.35 R\$ -1751.86 R\$ -80.06 R\$ -145.98	R\$ -335.48 R\$ -995.02 R\$ -5.99 R\$ -36.85
Resultado por retorno		69 35 operações	43 25 operações	112 60 operações
Resultado Líq. Res. médio por op.		R\$ 2814.22 R\$ 1850.39 R\$ 40.78 R\$ 52.86	R\$ -3626.49 R\$ -3156.98 R\$ -84.33 R\$ -126.27	R\$ -812.27 R\$ -1306.59 R\$ -7.25 R\$ -21.77


Fonte: Elaborada pelo autor (2022)

É interessante verificar que o uso de SGR melhorou o resultado médio das operações lucrativas (tanto de compra como de venda). Contudo, a redução da quantidade de operações tornou o lucro consolidado da estratégia com SGR (R\$ 1.850,39) menor do que aquele obtido pela estratégia sem uso de SGR (R\$ 2.814,22).

Quanto às operações que geraram prejuízo, também houve uma redução da quantidade (43 para 25) e uma potencialização do prejuízo médio dessas operações, aumentando de R\$ 84,33 para R\$ 126,27. Na consolidação final das operações com prejuízo, houve uma redução do prejuízo de R\$ 3.626,49 para R\$ 3.156,98. Essa diferença não foi superior à perda de lucro ocasionada pelo uso do SGR, e portanto, o resultado final da estratégia MACD (Posicionado) utilizando SGR foi um retorno líquido de -1,31%.


As Figuras 5.5.2.5 e 5.5.2.5 ilustram os *trades* realizados pela estratégia RSI sem o uso do SGR e com SGR, respectivamente. As cores azul e vermelho sinalizam se o resultado da operação foi positivo ou negativo.

Figura 5.26: USIM5 - *Trades* realizados pela estratégia MACD (Posicionado) sem uso do SGR



Fonte: Elaborada pelo autor (2022)

Figura 5.27: USIM5 - *Trades* realizados pela estratégia MACD (Posicionado) utilizando SGR



Fonte: Elaborada pelo autor (2022)

5.6 Considerações Finais

Os resultados apresentados neste capítulo permitem verificar uma forte relação do desempenho do SGR com a distribuição de erro de previsão do modelo utilizado. Quanto menor o intervalo de erro de previsão do modelo, mais preciso torna-se o Sistema de Gestão de Risco e, portanto, mais efetivo ele se torna na melhoria dos resultados apresentados pelas estratégias.

É importante observar que o SGR é uma segunda camada de aplicação, cabendo a ele filtrar os sinais de entradas para abertura de posições nos ativos em regiões mais promissoras para operações lucrativas. Ou seja, comprar em regiões próximas do mínimo previsto para o dia ou vender em regiões próximas do máximo previsto para o dia. O ponto de encerramento da operação cabe às próprias estratégias automatizadas.

A Tabela 5.30 demonstra que a utilização do SGR melhorou o retorno líquido das estratégias em 64% das execuções (29 de 45 execuções, sendo 9 estratégias por ativo) e um acréscimo médio no retorno líquido das estratégias de 0,31%.

As estratégias que mais se beneficiaram da utilização do SGR foram as estratégias de cruzamento de média (18 em 20 das execuções, efetividade de 90%) perfazendo um acréscimo médio no retorno líquido de 0,70%. As estratégias de cruzamento de média mostraram-se mais sensíveis ao SGR, devido à natureza de suas operações: quantidade elevada de operações intradiárias. O impacto principal do SGR materializa-se na redução da quantidade de operações, melhoria das taxas de acerto e melhoria da relação risco/ganho, o que reflete-se em melhores retornos líquidos, principalmente pela redução do custo total de transação.

As estratégias RSI e MACD, que realizam operações mais longas do que operações intradiárias e, portanto, uma quantidade menor de operações, apresentaram efetividade de 53,3 % (8 em 15 execuções) e acréscimo médio no retorno líquido de 0,05%. Como o intervalo entre o ponto de entrada e saída das operações são mais distantes em termos de preço e distância no tempo, o filtro realizado pelo SGR na abertura de posição ou reversão de posição apresenta um impacto marginal no resultado das operações e, portanto, as estratégias RSI e MACD mostraram-se menos sensíveis ao uso do SGR.

Verificou-se uma baixa sensibilidade das estratégias *Buy low/Sell high* e *Act on opening* ao uso do SGR. Isto deve-se ao fato de que pelo funcionamento dessas estratégias, o maior impacto do SGR se deu na aplicação de *stoploss*, o que na maior parte das situações dos testes realizados restringe a relação risco/ganho.

Em suma, a Tabela 5.31 permite observar a predominância das estratégias MACD (Posicionado) e RSI como estratégias mais lucrativas e que se beneficiaram do uso do SGR em 60% das situações (Tabela 5.30), apresentando retorno sobre o capital alocado nas operações superior ao *baseline* primário definido como a estratégia *buy-and-hold*.

Tabela 5.30: Efetividade da aplicação do SGR nas estratégias automatizadas

Estratégia	Utilização do SGR			
	Melhorou desempenho	Piorou desempenho	Efetividade SGR	Acréscimo médio no Retorno líquido
Buy low/Sell high	2	3	40%	-0.01%
Act on opening	1	4	20%	-0.09%
Cruzamento de média	5	-	100%	1.15%
Cruzamento de 2 médias	5	-	100%	0.74%
Cruzamento de 3 médias (C/ liquidação)	3	2	60%	0.16%
Cruzamento de 3 médias (Posicionado)	5	-	100%	0.74%
RSI	3	2	60%	-0.03%
MACD (C/ liquidação)	2	3	40%	-0.19%
MACD (Posicionado)	3	2	60%	0.36%
Efetividade Geral	29	16	64%	0.31%

Fonte: Elaborada pelo autor (2022)

Tabela 5.31: Estratégias com melhor desempenho utilizando SGR para cada ativo e retorno sobre capital alocado

Ativo	Estratégia com melhor desempenho utilizando SGR	Retorno sobre capital alocado	Retorno <i>baseline</i> Buy-and-hold
ABEV3	MACD (Posicionado)	13.3%	12.0%
B3SA3	RSI	39.2%	32.0%
ITUB4	RSI	10.9%	11.0%
PETR4	MACD (Posicionado)	19.20%	10%
USIM5	Buy low/Sell High	-3.50%	-7%

Fonte: Elaborada pelo autor (2022)

Capítulo 6

Conclusão

O desenvolvimento de um Sistema de Gestão de Risco baseado em modelos de predição de aprendizado profundo revelou-se um grande desafio. A concepção do sistema de gestão de risco fundamentou-se em predições realizadas por modelos LSTM e BiLSTM, e no desenvolvimento do trabalho, ficou evidente o elevado custo computacional e temporal para treinamento desses modelos, ainda que tenha sido empregado o uso de computação nas nuvens (*cloud computing*) em máquinas com GPUs e de forma paralela.

O treinamento dos modelos e obtenção de um preditor com menor média de erro médio quadrático demandou a experimentação de diferentes conjuntos de dados de entrada, sempre utilizando dados de preço dos ativos (OHLCV) e estrutura dos modelos (variação de tipo de modelo, quantidade de camadas, células e mecanismo de atenção). Os dados obtidos no treinamento dos modelos permitiu realizar um estudo estatístico do impacto de diferentes variáveis do modelo na métrica de desempenho (RMSE - raiz quadrada do erro médio quadrático), o qual é apresentado no Apêndice A.

Após a obtenção dos modelos de predição otimizados por ativo, analisou-se as distribuições dos erros de predição e utilizou-se de tal conhecimento para desenvolver as regras do sistema de gestão de risco. Verificou-se nos resultados um amplo intervalo de variação de erro de predição nos modelos obtidos, o que representou uma dificuldade na gestão de risco em operações intradiárias, bem como impacto em estratégias que realizam operações mais longas encobrendo vários dias. Os valores máximos e mínimos diários preditos pelos modelos, tendo em vista a magnitude dos erros, permitia a abertura de posições inversas às tendências diárias de preço e, portanto, tornou-se necessário incorporar outros elementos de restrição e funcionamento do SGR, tais abrir posições apenas após uma hora de pregão a fim de ter uma incerteza estatística menor sobre a direção de movimentação do ativo no dia (alta ou baixa). Ficou evidente que o desempenho do SGR seria tão melhor quanto menor fossem os erros de predição dos modelos.

Dada a distribuição dos erros de predição dos modelos e o grau de incerteza, um elemento principal no desenvolvimento do SGR foi o ajuste dos valores previstos de acordo com a tendência diária com base nos percentis de distribuição de erro dos preditores. Esta adaptação visou reduzir a ocorrência de operações contra a tendência diária dos preços em função dos erros na predição dos valores máximo e mínimo do ativo.

A aplicação do Sistema de Gestão de Risco sobre as estratégias automatizadas demonstrou uma efetividade geral de 64%, melhorando o retorno financeiro líquido das estratégias sem a utilização do SGR por meio do incremento da taxa de acerto e relação risco/ganho e redução da quantidade de operações. O acréscimo médio do retorno financeiro líquido em função do uso do SGR foi de 0,31%.

A efetividade do SGR foi maior nas estratégias com elevado número de operações (cruzamento de média), apresentando um ganho médio do retorno líquido de 0,7%. Já para as estratégias que produziam posições que duravam mais que um dia (RSI e MACD), a efetividade foi menor e o ganho médio no retorno líquido foi de 0,05%. A sensibilidade maior das estratégias de cruzamento de média em relação à RSI e MACD deve-se a dois fatores: a filtragem de abertura de posições nas estratégias de cruzamento de média tem o impacto de reduzir o custo de transação; o impacto do SGR é marginal nas operações realizadas pelas estratégias RSI e MACD dado que o intervalo de preço das operações (entrada e saída) é geralmente maior do que os erros de predição dos modelos.

É importante evidenciar que o SGR visa potencializar as estratégias automatizadas por meio da redução de operações não lucrativas, melhoria da taxa de acerto e da relação risco/ganho. No entanto, o resultado líquido das estratégias é de certa forma ancorado pela forma de operação da estratégia, uma vez que as aberturas de operações são filtradas pelo SGR, mas os pontos de saída são fornecidos pela própria estratégia. Assim, um ponto relevante a ser observado é que as estratégias que apresentaram melhor desempenho utilizando o Sistema de Gestão de Risco tiveram um retorno sobre o capital alocado nas operações maior do que o *baseline* primário (estratégia *buy-and-hold*) em todos os ativos abordados neste trabalho. A única exceção foi para o ativo ITUB4, no qual o retorno sobre o capital alocado utilizando a estratégia MACD (Posicionado) com SGR foi de 10,9%, enquanto o *baseline* foi de 11%.

Enfim, conclui-se que o desenvolvimento de um sistema de gestão de risco, da forma como foi proposto nesta dissertação, apresentou resultados dentro das expectativas. O desempenho do SGR é bastante correlacionado ao grau de incerteza das predições realizadas pelos modelos de predição otimizados. Esta era uma limitação já esperada no trabalho, dado que as predições diárias utilizam apenas dados até o momento de abertura do pregão, desconsiderando nestas predições fatos e eventos (políticos, econômicos, etc..) que ocorrem durante o horário do pregão e que impactam de forma mais significativa o preço do ativo do que o histórico recente de movimentação do mesmo.

Como propostas de trabalhos futuros, pode-se elencar o estudo e obtenção de modelos de predição que apresentem uma melhor distribuição de erros de predição, utilizando como dados de entrada para treinamento dos modelos variáveis que capturem a dinâmica de negociação do ativo no dia que está sendo previsto os valores máximo e mínimo. Outra alternativa seria a utilização de modelos que atualizem a predição inicial dos valores máximo e mínimo do ativo com base em informações de negociação dos ativos em tempo

próximo do tempo real. Certamente, a melhoria das curvas de distribuição de erro dos valores preditos pelo modelo é uma condição *sine qua non* para aperfeiçoamento do desempenho do Sistema de Gestão de Risco.

Referências

- B3. Site b3. https://www.b3.com.br/pt_br/produtos-e-servicos/tarifas/listados-a-vista-e-derivativos/renda-variavel/tarifas-de-acoes-e-fundos-de-investimento/a-vista/, 2022. Acessado em 28 de Fevereiro de 2022.
- Dzmitry Bahdanau, Kyunghyun Cho, and Yoshua Bengio. Neural machine translation by jointly learning to align and translate, 2016.
- Wei Bao, Jun Yue, and Yulei Rao. A deep learning framework for financial time series using stacked autoencoders and long-short term memory. *PLOS ONE*, 12(7):1–24, 07 2017. doi: 10.1371/journal.pone.0180944. URL <https://doi.org/10.1371/journal.pone.0180944>.
- CMN. Cmn 3.271/2009. https://www.bcb.gov.br/pre/normativos/res/2009/pdf/res_3721_v1_0.pdf, 2021. Acessado em 21 de Setembro de 2021.
- CMN. Cmn 4.090/2012. https://www.bcb.gov.br/pre/normativos/res/2012/pdf/res_4090_v1_0.pdf, 2021. Acessado em 21 de Setembro de 2021.
- CMN. Cmn 4.557/2017. https://www.in.gov.br/materia/-/asset_publisher/Kujrw0TZC2Mb/content/id/20471202/doi-2017-03-01-resolucao-n-4-557-de-23-de-fevereiro-de-2017-20471020, 2021. Acessado em 21 de Setembro de 2021.
- Dicionário de Cambridge. Dicionário de cambridge. <https://dictionary.cambridge.org/pt/dicionario/portugues-ingles/risco>, 2021. Acessado em 21 de Setembro de 2021.
- Dicionário de Merriam-Webster. Dicionário de merriam-webster. <https://www.merriam-webster.com/dictionary/risk>, 2021. Acessado em 21 de Setembro de 2021.
- Bússola do Investidor. Bússola do investidor. <https://www.bussoladoinvestidor.com.br/>, 2007. Acessado em 30 de Novembro de 2015.
- Thomas Fischer and Christopher Krauss. Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2):654 – 669, 2018. ISSN 0377-2217. doi: <https://doi.org/10.1016/j.ejor.2018.05.044>.

1016/j.ejor.2017.11.054. URL <http://www.sciencedirect.com/science/article/pii/S0377221717310652>.

Wayne A Fuller. *Introduction to statistical time series*. John Wiley & Sons, 2009.

Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. *Neural Computation*, 9(8):1735–1780, 11 1997. ISSN 0899-7667. doi: 10.1162/neco.1997.9.8.1735. URL <https://doi.org/10.1162/neco.1997.9.8.1735>.

Ronen Israel, Bryan T. Kelly, and Tobias J. Moskowitz. Can machines 'learn' finance? *Journal of Investment Management*, 01 2020. URL <https://ssrn.com/abstract=3624052>.

Jr. J. L. Kelly. A new interpretation of information rate. 3 1956.

Eduardo Jabbur. *Um arcabouço de algoritmos de aprendizado de máquina para avaliação de estratégias de investimento para o mercado de ações*. PhD thesis, Centro Federal de Educação Tecnológica de Minas Gerais, 2020.

Rosdyana Mangir Irawan Kusuma, Trang-Thi Ho, Wei-Chun Kao, Yu-Yen Ou, and Kai-Lung Hua. Using deep learning neural networks and candlestick chart representation to predict stock market, 2019. URL <https://arxiv.org/abs/1903.12258>.

Luciana Malagrino, Norton Roman, and Ana Monteiro. Forecasting stock market index daily direction: a bayesian network approach. *Expert Systems with Applications*, 105, 03 2018. doi: 10.1016/j.eswa.2018.03.039.

Henry B Mann and Donald R Whitney. On a test of whether one of two random variables is stochastically larger than the other. *The annals of mathematical statistics*, pages 50–60, 1947.

J.P Morgan. *RiskMetrics — Technical Document*. J.P.Morgan/Reuters, 1996.

Kenny Olorunnimbe and Herna Viktor. Deep learning in the stock market—a systematic survey of practice, backtesting, and applications. *Artificial Intelligence Review*, 105, 06 2022. doi: 10.1007/s10462-022-10226-0.

Berat Sezer Omer, Ugur Gudelek Mehmet, and Murat Ozbayoglu Ahmet. Financial time series forecasting with deep learning : A systematic literature review: 2005–2019. *Applied Soft Computing*, 90:106181, 2020. ISSN 1568-4946. doi: <https://doi.org/10.1016/j.asoc.2020.106181>. URL <http://www.sciencedirect.com/science/article/pii/S1568494620301216>.

Murat Ozbayoglu, Ugur Gudelek, and Omer Sezer. Deep learning for financial applications : A survey. *Applied Soft Computing*, page 106384, 05 2020. doi: 10.1016/j.asoc.2020.106384.

-
- Jiayu Qiu, Bin Wang, and Changjun Zhou. Forecasting stock prices with long-short term memory neural network based on attention mechanism. *PLOS ONE*, 15(1):1–15, 01 2020. doi: 10.1371/journal.pone.0227222. URL <https://doi.org/10.1371/journal.pone.0227222>.
- Mike Schuster and Kuldip Paliwal. Bidirectional recurrent neural networks. *Signal Processing, IEEE Transactions on*, 45:2673 – 2681, 12 1997. doi: 10.1109/78.650093.
- S. Selvin, R. Vinayakumar, E. A. Gopalakrishnan, V. K. Menon, and K. P. Soman. Stock price prediction using lstm, rnn and cnn-sliding window model. In *2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, pages 1643–1647, 2017.
- Samuel Sanford Shapiro and Martin B Wilk. An analysis of variance test for normality (complete samples). *Biometrika*, 52(3/4):591–611, 1965.
- S. Siami-Namini, N. Tavakoli, and A. Siami Namin. A comparison of arima and lstm in forecasting time series. In *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)*, pages 1394–1401, 2018.
- Edward O. Thorp, Leonard C. MacLean, Yonggan Zhao, and William T. Ziemba. Medium term simulations of the full kelly and fractional kelly investment strategies. 1 2010. URL <http://www.edwardthorp.com/wp-content/uploads/2016/11/KellySimulationsNew.pdf>.
- Jerome Friedman Trevor Hastie, Robert Tibshirani. *The Elements of Statistical Learning*. Springer, 2009.
- Frank Wilcoxon. Individual comparisons by ranking methods. In *Breakthroughs in statistics*, pages 196–202. Springer, 1992.
- Jun Xie, Bo Chen, Xinglong Gu, Fengmei Liang, and Xinying Xu. Self-attention-based bilstm model for short text fine-grained sentiment classification. *IEEE Access*, 7:1–1, 12 2019. doi: 10.1109/ACCESS.2019.2957510.

Apêndice A

Testes estatísticos dos modelos treinados

A.1 Análise do desempenho de modelos de acordo com dados de entrada

A primeira análise realizada visa identificar se as distribuições de amostras de RMSE para cada conjunto de dados de entrada e ativo são distribuições normais e se são originárias de uma mesma distribuição.

As Tabelas [A.1](#) a [A.5](#) apresentam na diagonal principal o resultado dos testes de normalidade *Shapiro-Wilk* para os quatro conjuntos de amostras RMSE, enquanto nas demais células verifica-se a aplicação do teste *Mann-Whitney* entre os pares de distribuições de amostras de RMSE a fim de identificar se pertencem a uma mesma distribuição.

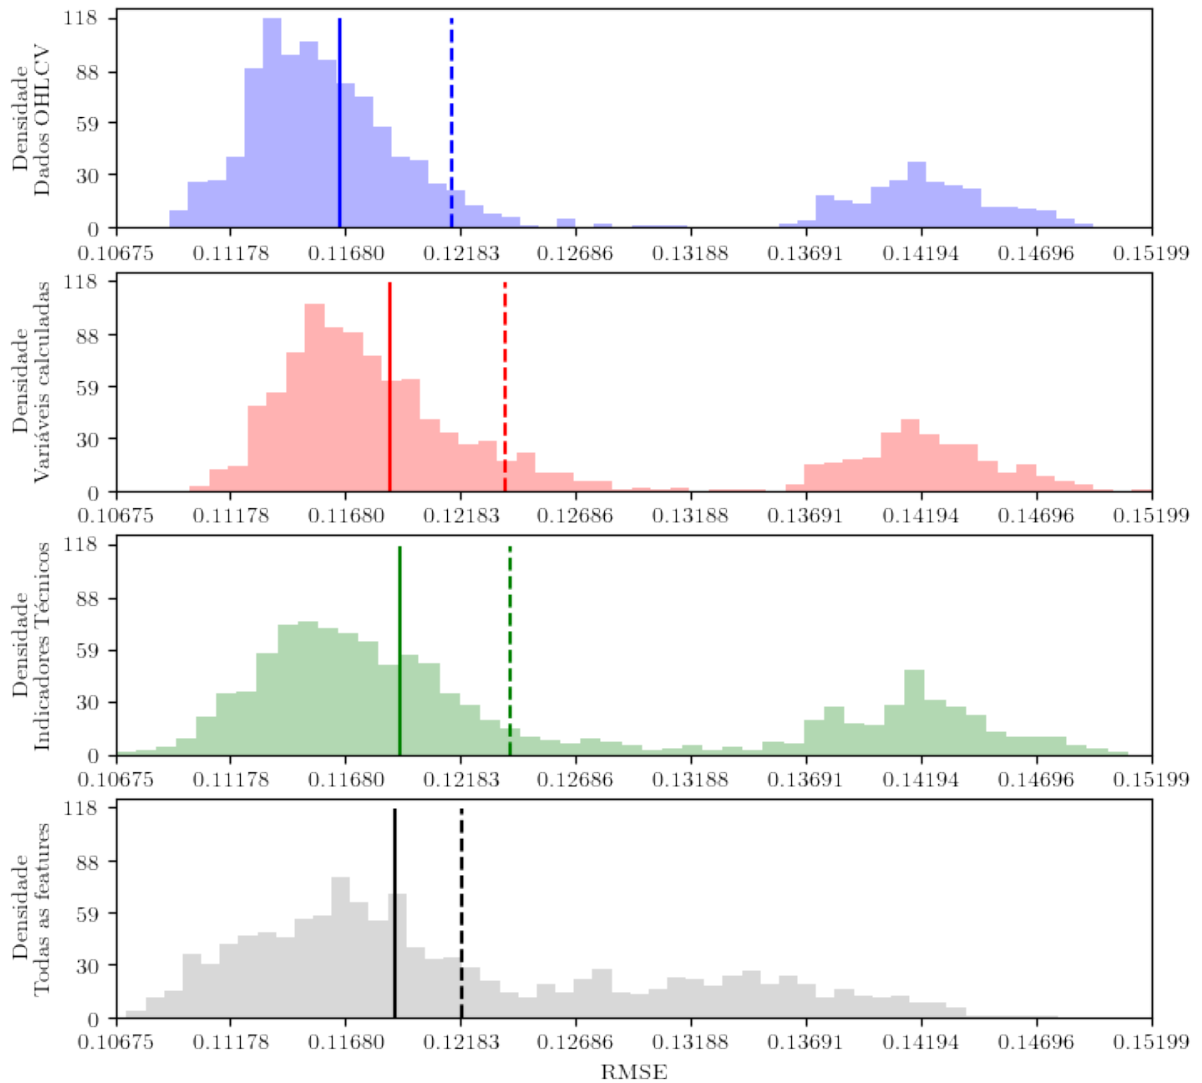
Verificou-se pelos testes estatísticos que nenhuma das amostras testadas é proveniente de uma distribuição normal, bem como nenhum par de amostras demonstrou ser originário de uma mesma distribuição. Assim sendo, pode-se afirmar que os modelos treinados apenas com dados de log-retorno (OHLCV) resultam na média em modelos com melhores valores de RMSE, pois a distribuição apresenta mediana e média menores. As Figuras [A.1](#) a [A.5](#) apresentam as amostras de RMSE para cada conjunto de entrada e ativo, bem como a média (linha tracejada) e a mediana das amostras (linha sólida).

Tabela A.1: ABEV3 - Testes de normalidade *Shapiro-Wilk* e *Mann-Whitney* entre pares de amostras RMSE para cada conjunto de dados de entrada

Amostras de RMSE dos modelos treinados para ABEV3	OHLCV	OHLCV + Var. adicionais	OHLCV + Ind. Técnicos	OHLCV + Variáveis calculadas + Ind. Técnicos
OHLCV	0,747 ($p \approx 0$)			
OHLCV + Var. adicionais	1.269.176 ($p \approx 0$)	0,798 ($p \approx 0$)		
OHLCV + Ind. Técnicos	1.331.099 ($p \approx 0$)	1.596.669 ($p \approx 0$)	0,844 ($p \approx 0$)	
OHLCV + Variáveis calculadas + Ind. Técnicos	1.444.393 ($p \approx 0$)	1.481.845 ($p \approx 0$)	1.484.836 ($p \approx 0$)	0,923 ($p \approx 0$)

Fonte: Elaborada pelo autor (2022)

Figura A.1: ABEV3 - Distribuição de RMSE dos modelos treinados por cada conjunto de dados de entrada



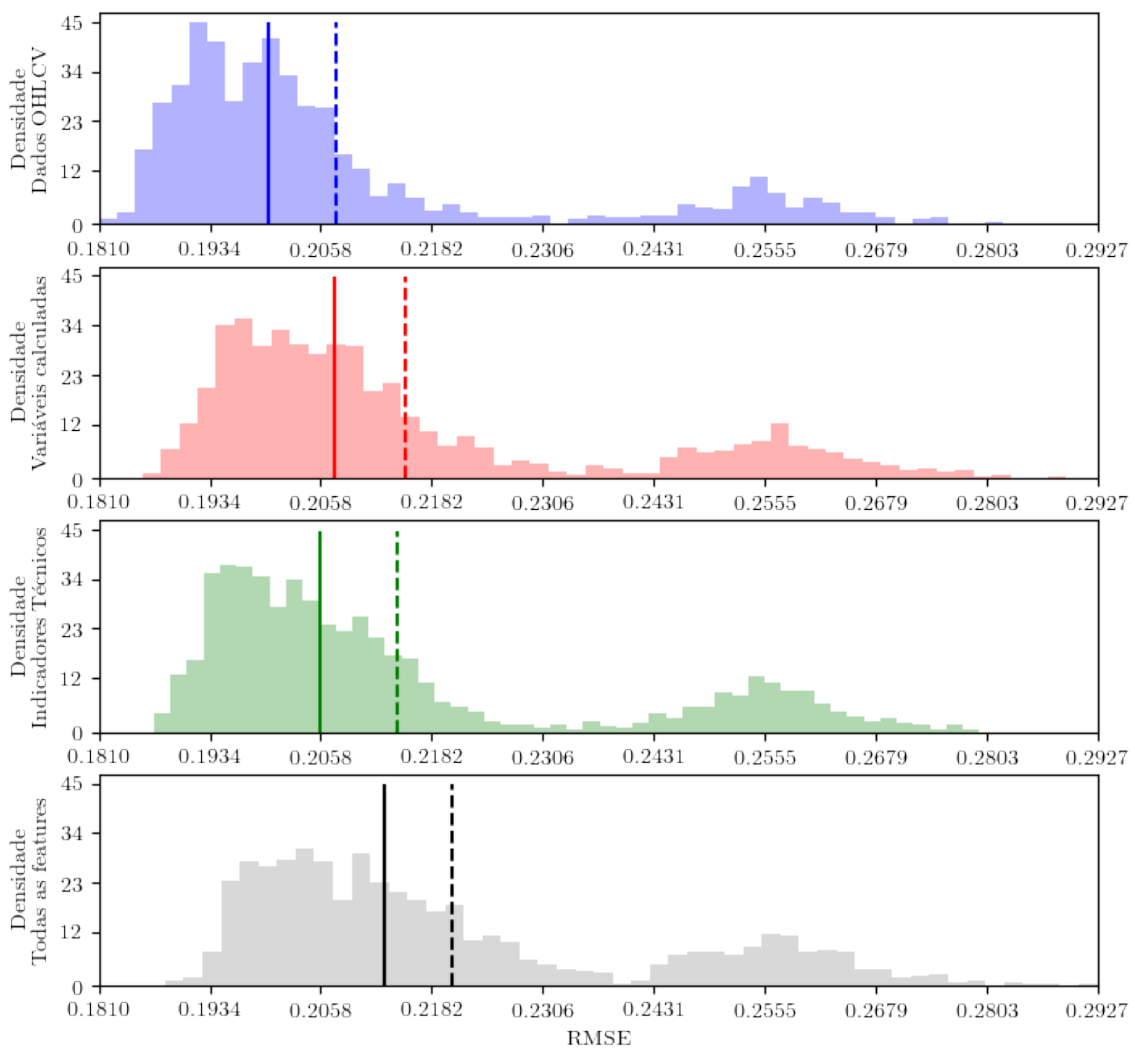
Fonte: Elaborada pelo autor (2022)

Tabela A.2: B3SA3 - Testes de normalidade *Shapiro-Wilk* e *Mann-Whitney* entre pares de amostras RMSE para cada conjunto de dados de entrada

Amostras de RMSE dos modelos treinados para B3SA3	OHLCV	OHLCV + Var. adicionais	OHLCV + Ind. Técnicos	OHLCV + Variáveis calculadas + Ind. Técnicos
OHLCV	0,772 ($p \approx 0$)			
OHLCV + Var. adicionais	1.127.531 ($p \approx 0$)	0,834 ($p \approx 0$)		
OHLCV + Ind. Técnicos	1.196.355 ($p \approx 0$)	1.542.591 ($p \approx 0$)	0,819 ($p \approx 0$)	
OHLCV + Variáveis calculadas + Ind. Técnicos	879.820 ($p \approx 0$)	1.310.495 ($p \approx 0$)	1.246.399 ($p \approx 0$)	0,877 ($p \approx 0$)

Fonte: Elaborada pelo autor (2022)

Figura A.2: B3SA3 - Distribuição de RMSE dos modelos treinados por cada conjunto de dados de entrada



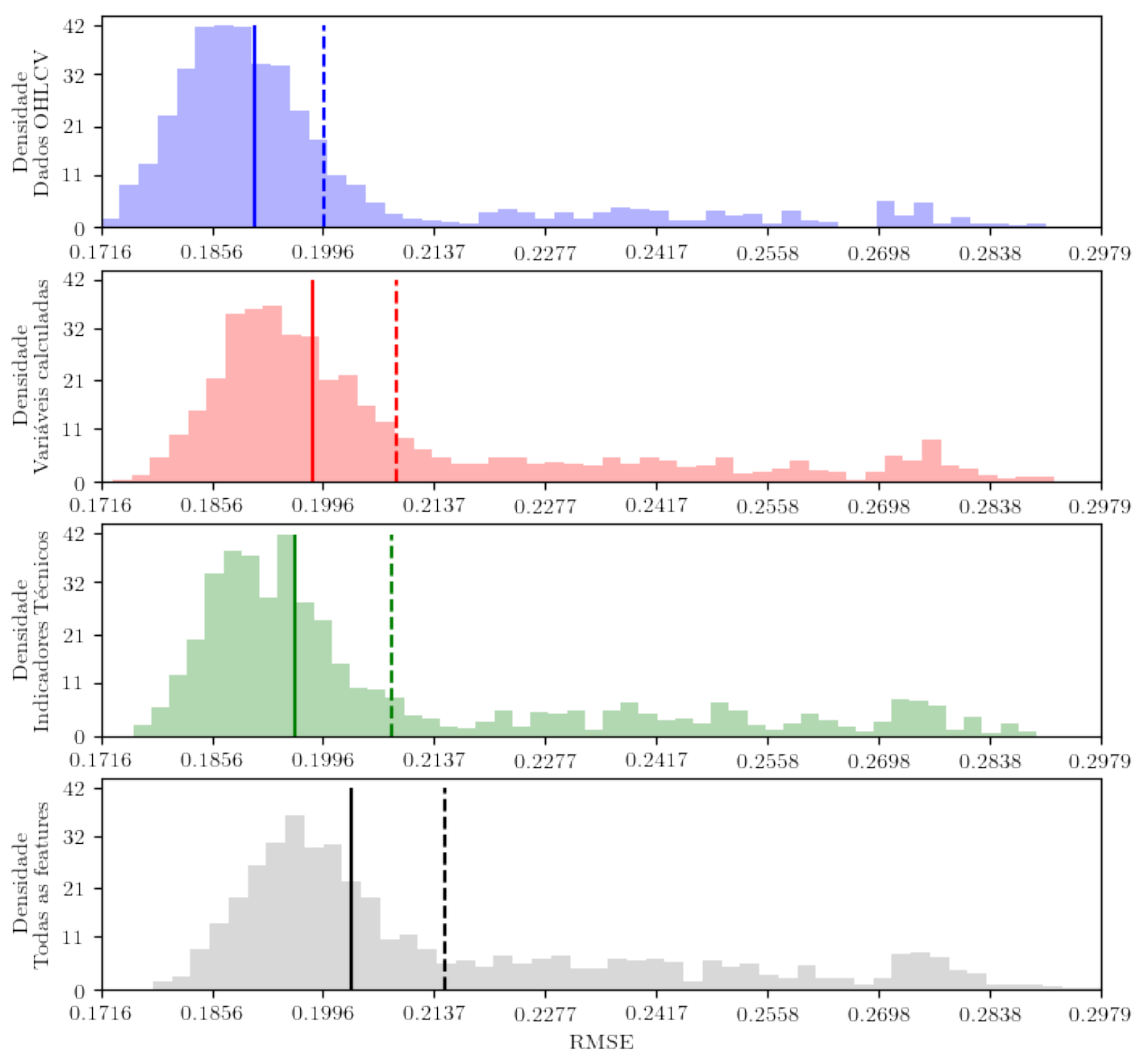
Fonte: Elaborada pelo autor (2022)

Tabela A.3: ITUB4 - Testes de normalidade *Shapiro-Wilk* e *Mann-Whitney* entre pares de amostras RMSE para cada conjunto de dados de entrada

Amostras de RMSE dos modelos treinados para ITUB4	OHLCV	OHLCV + Var. adicionais	OHLCV + Ind. Técnicos	OHLCV + Variáveis calculadas + Ind. Técnicos
OHLCV	0,738 ($p \approx 0$)			
OHLCV + Var. adicionais	1.095.006 ($p \approx 0$)	0,811 ($p \approx 0$)		
OHLCV + Ind. Técnicos	1.194.132 ($p \approx 0$)	1.512.587 ($p \approx 0$)	0,797 ($p \approx 0$)	
OHLCV + Variáveis calculadas + Ind. Técnicos	853.570 ($p \approx 0$)	1.332.298 ($p \approx 0$)	1.240.722 ($p \approx 0$)	0,852 ($p \approx 0$)

Fonte: Elaborada pelo autor (2022)

Figura A.3: ITUB4 - Distribuição de RMSE dos modelos treinados por cada conjunto de dados de entrada



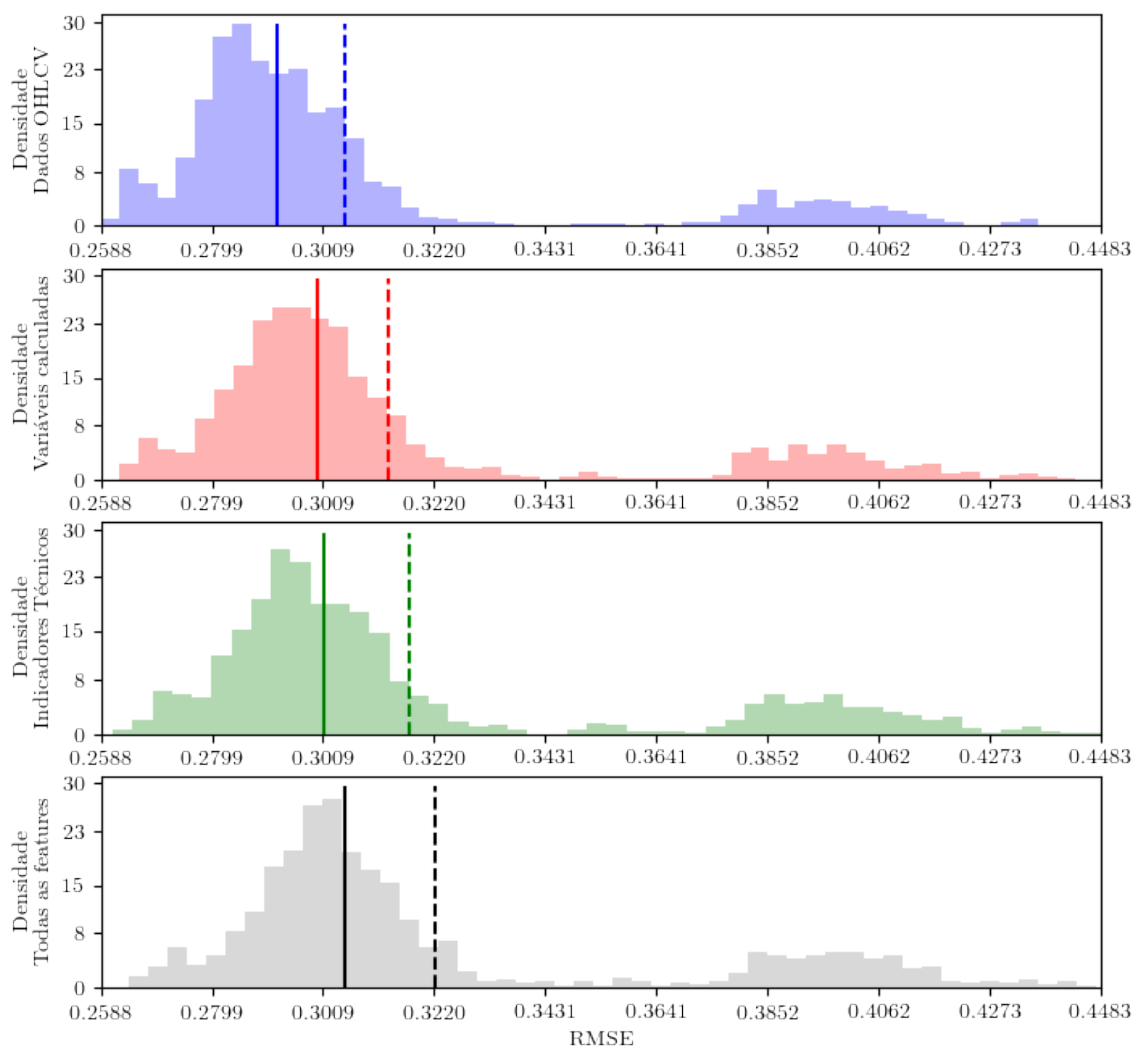
Fonte: Elaborada pelo autor (2022)

Tabela A.4: PETR4 - Testes de normalidade *Shapiro-Wilk* e *Mann-Whitney* entre pares de amostras RMSE para cada conjunto de dados de entrada

Amostras de RMSE dos modelos treinados para PETR4	OHLCV	OHLCV + Var. adicionais	OHLCV + Ind. Técnicos	OHLCV + Variáveis calculadas + Ind. Técnicos
OHLCV	0,725 ($p \approx 0$)			
OHLCV + Var. adicionais	1.259.729 ($p \approx 0$)	0,769 ($p \approx 0$)		
OHLCV + Ind. Técnicos	1.181.901 ($p \approx 0$)	1.528.159 ($p \approx 0$)	0,784 ($p \approx 0$)	
OHLCV + Variáveis calculadas + Ind. Técnicos	998.275 ($p \approx 0$)	1.319.997 ($p \approx 0$)	1.410.872 ($p \approx 0$)	0,803 ($p \approx 0$)

Fonte: Elaborada pelo autor (2022)

Figura A.4: PETR4 - Distribuição de RMSE dos modelos treinados por cada conjunto de dados de entrada



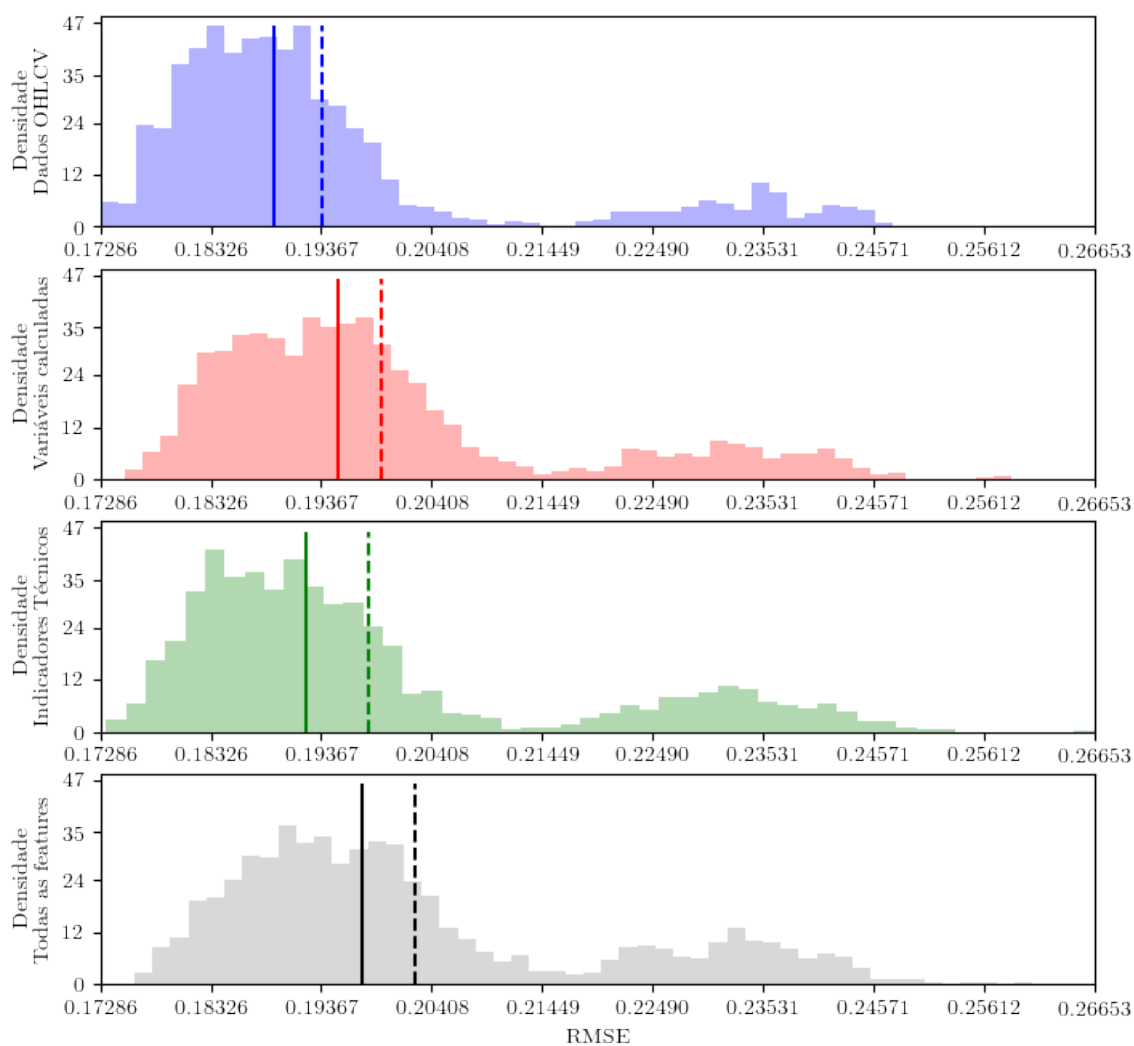
Fonte: Elaborada pelo autor (2022)

Tabela A.5: USIM5 - Testes de normalidade *Shapiro-Wilk* e *Mann-Whitney* entre pares de amostras RMSE para cada conjunto de dados de entrada

Amostras de RMSE dos modelos treinados para USIM5	OHLCV	OHLCV + Var. adicionais	OHLCV + Ind. Técnicos	OHLCV + Variáveis calculadas + Ind. Técnicos
OHLCV	0,777 ($p \approx 0$)			
OHLCV + Var. adicionais	1.148.294 ($p \approx 0$)	0,862 ($p \approx 0$)		
OHLCV + Ind. Técnicos	1.347.929 ($p \approx 0$)	1.438.154 ($p \approx 0$)	0,836 ($p \approx 0$)	
OHLCV + Variáveis calculadas + Ind. Técnicos	1.008.623 ($p \approx 0$)	1.443.635 ($p \approx 0$)	1.286.296 ($p \approx 0$)	0,888 ($p \approx 0$)

Fonte: Elaborada pelo autor (2022)

Figura A.5: USIM5 - Distribuição de RMSE dos modelos treinados por cada conjunto de dados de entrada



Fonte: Elaborada pelo autor (2022)

A.2 Desempenho de redes LSTM e BiLSTM

Esta segunda análise visa avaliar se para uma mesma estrutura de modelo, qual tipo de rede apresenta melhor resultado em termos de RMSE: LSTM ou BiLSTM.

As Tabelas [A.6](#) a [A.10](#) apresentam os resultados dos testes de normalidade *Shapiro-Wilk* para os conjuntos de amostras de modelos LSTM/BiLSTM de cada conjunto de dados de entrada, bem como o teste *Mann-Whitney* entre os modelos LSTM e BiLSTM a fim de identificar se as amostras pertencem a uma mesma distribuição.

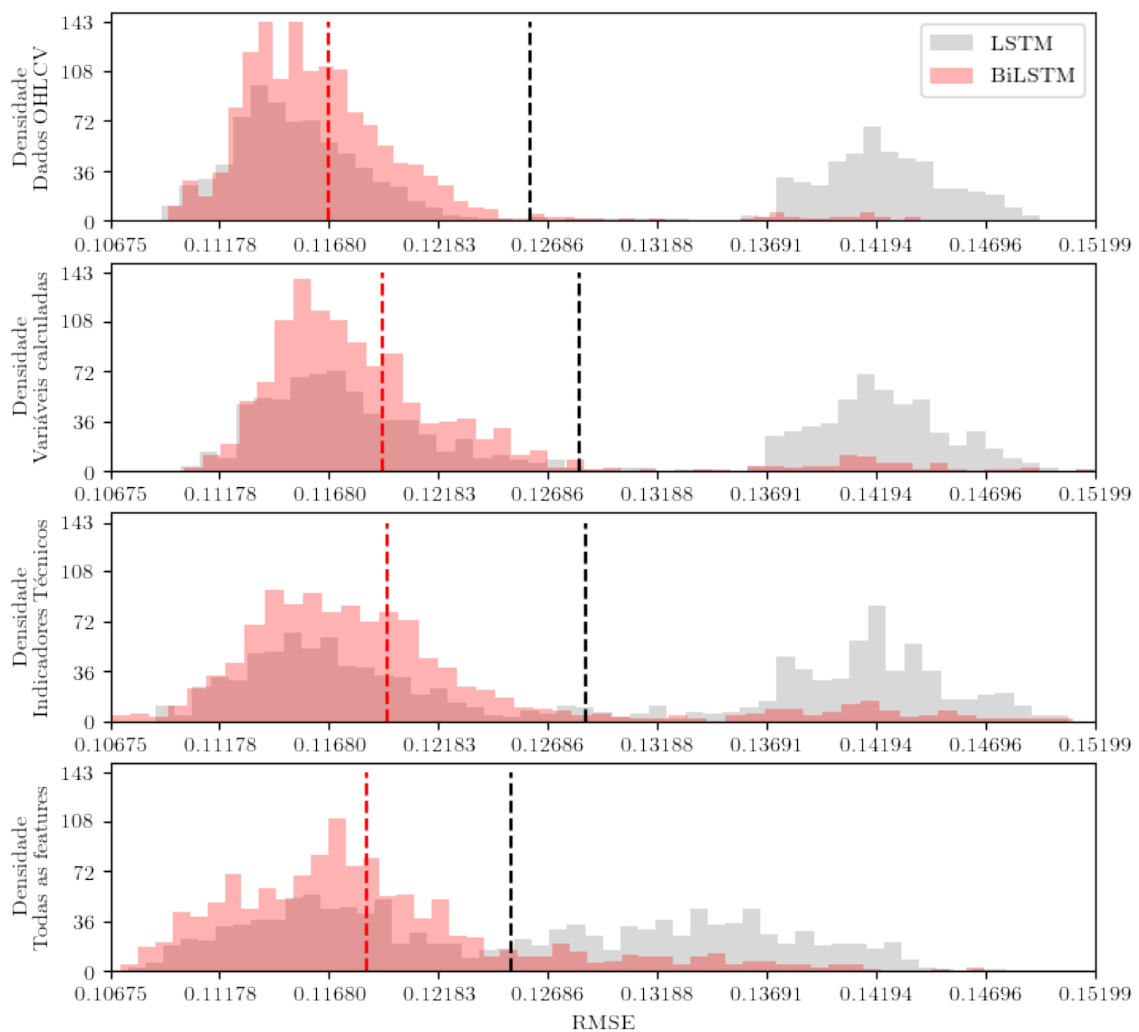
Verifica-se pelos resultados dos testes estatísticos que nenhuma das amostras é oriunda de uma distribuição normal e que as redes BiLSTM apresentam melhores resultados de RMSE, quando comparadas a uma rede LSTM com mesma estrutura. Observa-se também que a média do RMSE das amostras dos modelos LSTM (linha preta tracejada) foi sempre maior do que a média do RMSE das amostras dos modelos BiLSTM (linha tracejada vermelha). As Figuras [A.6](#) a [A.10](#) apresentam as amostras de RMSE dos modelos LSTM/BiLSTM para cada dado de entrada da rede e ativo.

Tabela A.6: ABEV3 - Testes de normalidade *Shapiro-Wilk* e *Mann-Whitney* entre amostras de modelos LSTM e BiLSTM

Conjunto amostral RMSE ABEV3	Teste normalidade Shapiro-Wilk		Teste Wilcoxon Signed-Rank entre modelo LSTM/BiLSTM
	LSTM	BiLSTM	
OHLCV	0,801 ($p \approx 0$)	0,761 ($p \approx 0$)	86.732 ($p \approx 0$)
OHLCV + Var. adicionais	0,838 ($p \approx 0$)	0,745 ($p \approx 0$)	73.594 ($p \approx 0$)
OHLCV + Ind. Técnicos	0,866 ($p \approx 0$)	0,801 ($p \approx 0$)	66.656 ($p \approx 0$)
OHLCV + Variáveis calculadas + Ind. Técnicos	0,944 ($p \approx 0$)	0,908 ($p \approx 0$)	74.342 ($p \approx 0$)

Fonte: Elaborada pelo autor (2022)

Figura A.6: ABEV3 - Distribuição de RMSE dos modelos LSTM/BiLSTM treinados por cada conjunto de dados de entrada



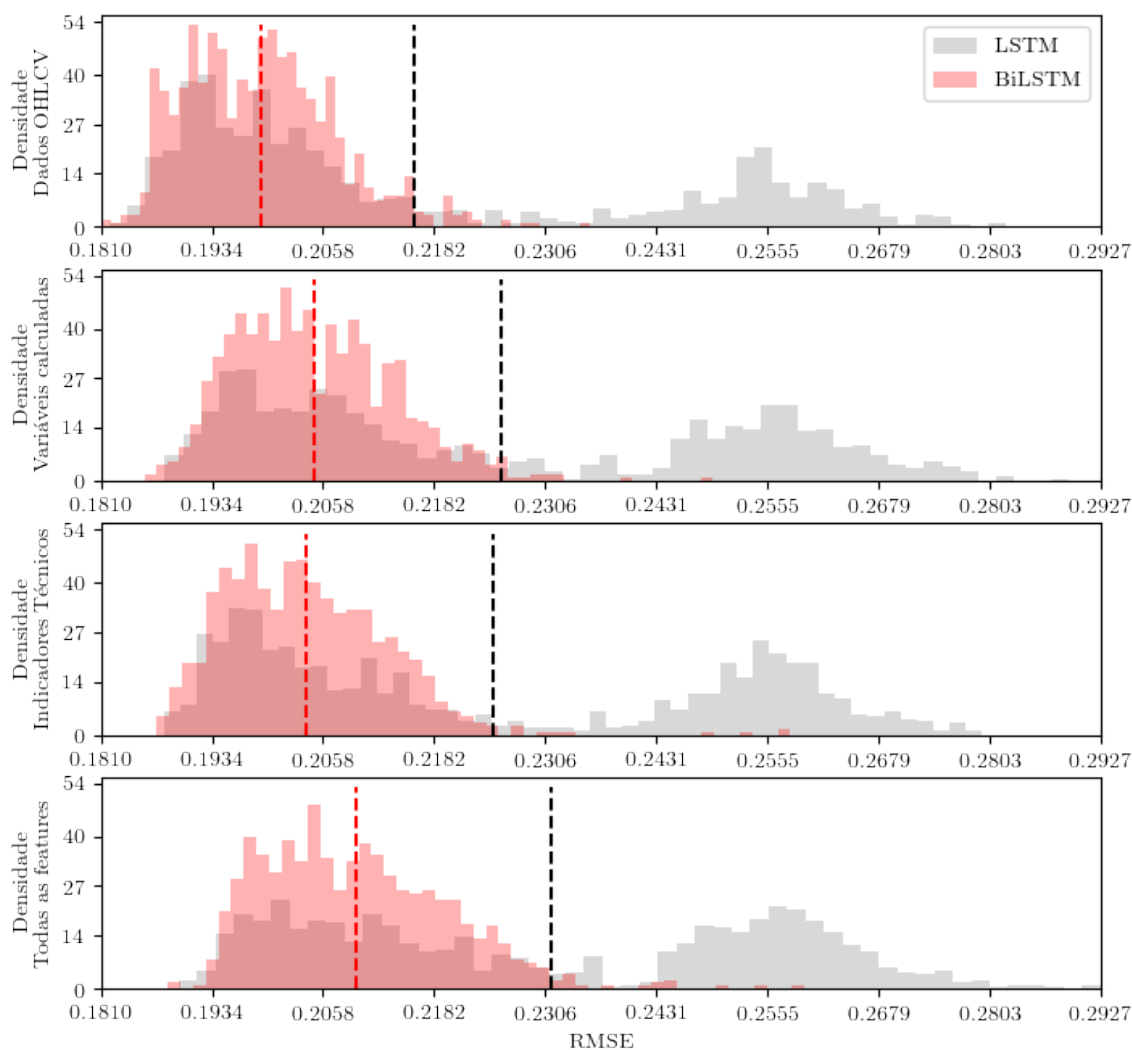
Fonte: Elaborada pelo autor (2022)

Tabela A.7: B3SA3 - Testes de normalidade *Shapiro-Wilk* e *Mann-Whitney* entre amostras de modelos LSTM e BiLSTM

Conjunto amostral RMSE B3SA3	Teste normalidade Shapiro-Wilk		Teste Wilcoxon Signed-Rank entre modelo LSTM/BiLSTM
	LSTM	BiLSTM	
OHLCV	0,837 ($p \approx 0$)	0,970 ($p \approx 0$)	78.669 ($p \approx 0$)
OHLCV + Var. adicionais	0,893 ($p \approx 0$)	0,976 ($p \approx 0$)	61.886 ($p \approx 0$)
OHLCV + Ind. Técnicos	0,872 ($p \approx 0$)	0,945 ($p \approx 0$)	55.998 ($p \approx 0$)
OHLCV + Variáveis calculadas + Ind. Técnicos	0,919 ($p \approx 0$)	0,960 ($p \approx 0$)	51.324 ($p \approx 0$)

Fonte: Elaborada pelo autor (2022)

Figura A.7: B3SA3 - Distribuição de RMSE dos modelos LSTM/BiLSTM treinados por cada conjunto de dados de entrada



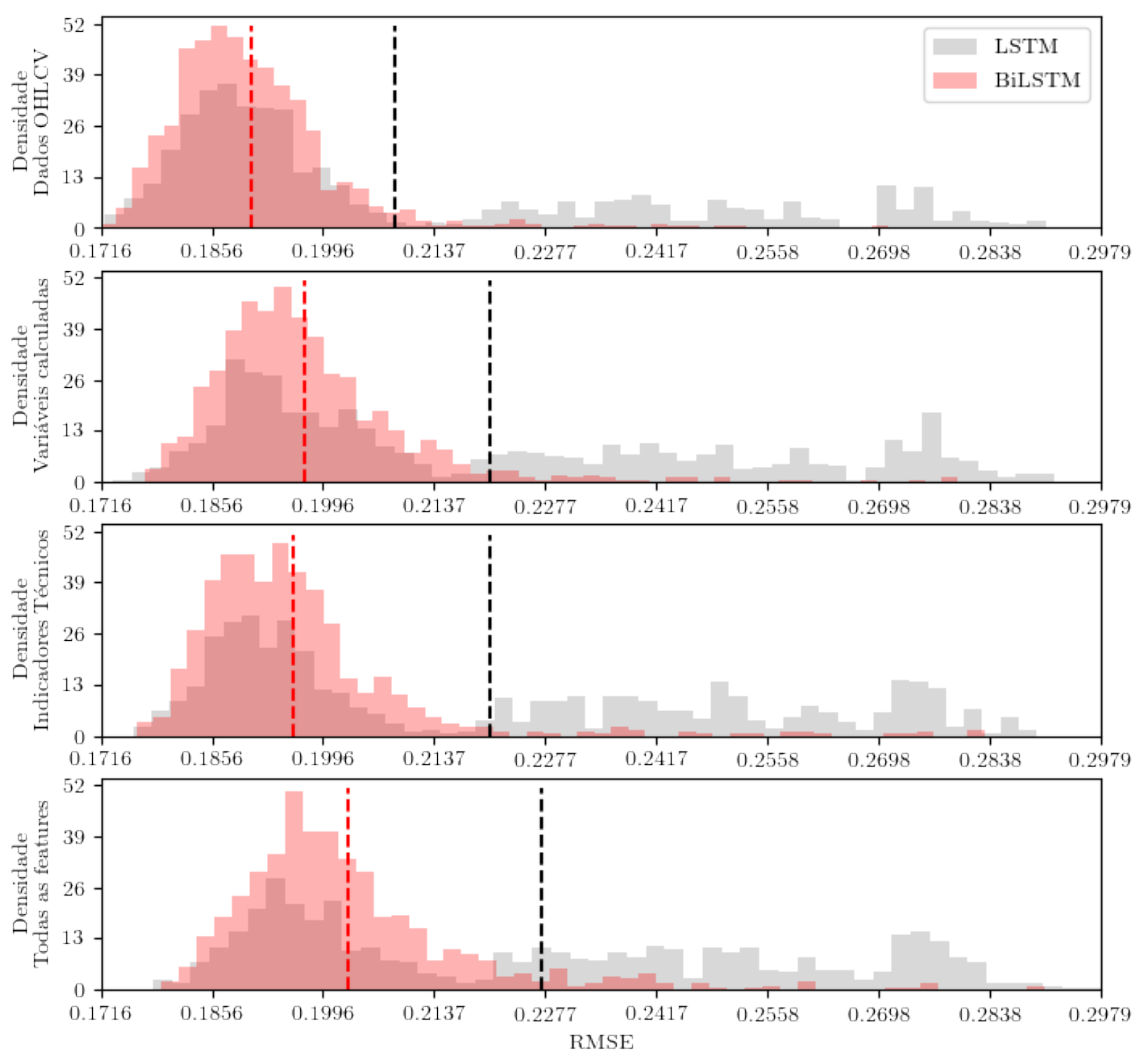
Fonte: Elaborada pelo autor (2022)

Tabela A.8: ITUB4 - Testes de normalidade *Shapiro-Wilk* e *Mann-Whitney* entre amostras de modelos LSTM e BiLSTM

Conjunto amostral RMSE ITUB4	Teste normalidade Shapiro-Wilk		Teste Wilcoxon Signed-Rank entre modelo LSTM/BiLSTM
	LSTM	BiLSTM	
OHLCV	0,823 ($p \approx 0$)	0,844 ($p \approx 0$)	88,458 ($p \approx 0$)
OHLCV + Var. adicionais	0,894 ($p \approx 0$)	0,841 ($p \approx 0$)	63,888 ($p \approx 0$)
OHLCV + Ind. Técnicos	0,885 ($p \approx 0$)	0,748 ($p \approx 0$)	70,700 ($p \approx 0$)
OHLCV + Variáveis calculadas + Ind. Técnicos	0,917 ($p \approx 0$)	0,837 ($p \approx 0$)	58,594 ($p \approx 0$)

Fonte: Elaborada pelo autor (2022)

Figura A.8: ITUB4 - Distribuição de RMSE dos modelos LSTM/BiLSTM treinados por cada conjunto de dados de entrada



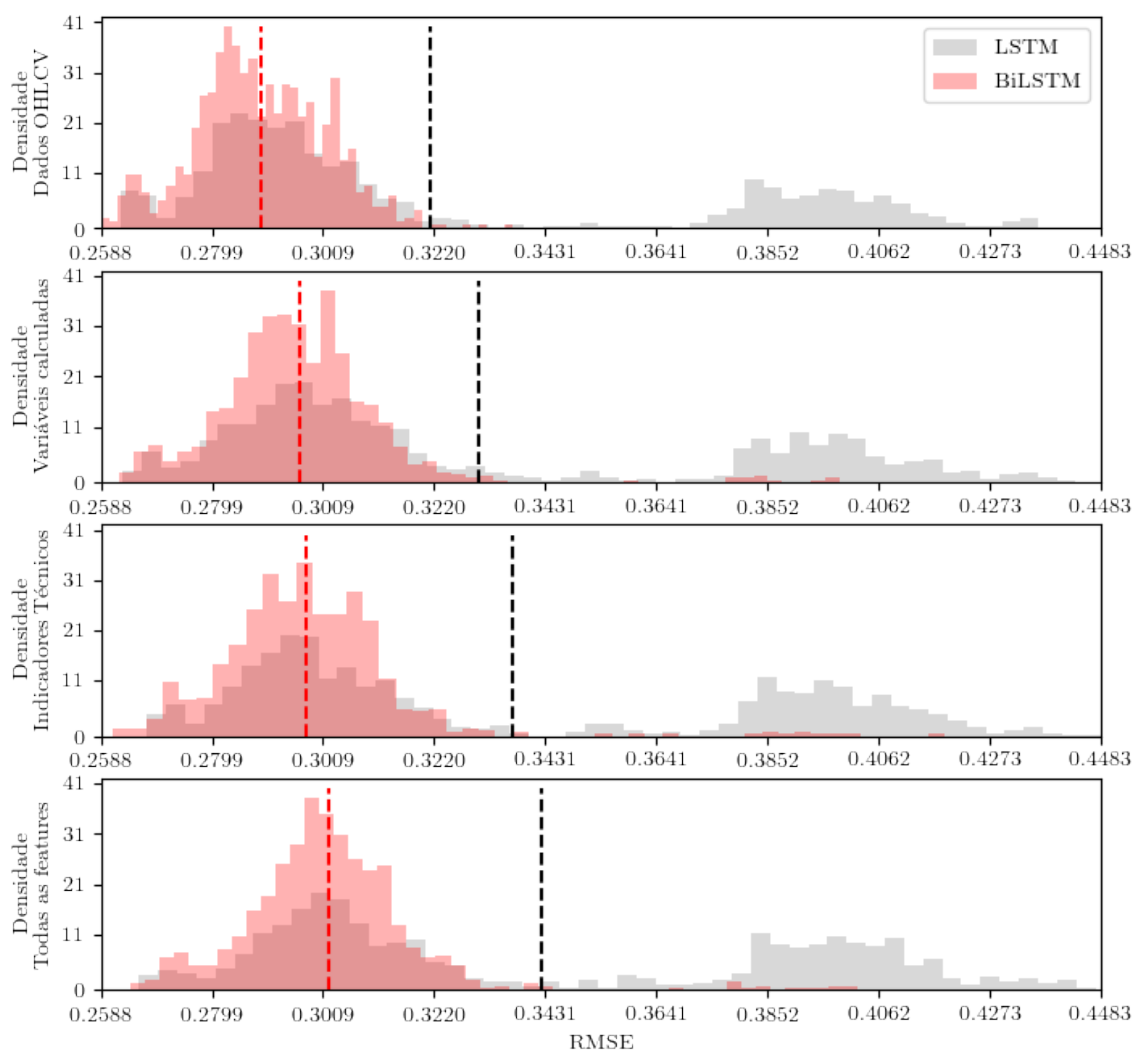
Fonte: Elaborada pelo autor (2022)

Tabela A.9: PETR4 - Testes de normalidade *Shapiro-Wilk* e *Mann-Whitney* entre amostras de modelos LSTM e BiLSTM

Conjunto amostral RMSE PETR4	Teste normalidade Shapiro-Wilk		Teste Wilcoxon Signed-Rank entre modelo LSTM/BiLSTM
	LSTM	BiLSTM	
OHLCV	0,807 ($p \approx 0$)	0,994 ($p \approx 0$)	48.994 ($p \approx 0$)
OHLCV + Var. adicionais	0,852 ($p \approx 0$)	0,853 ($p \approx 0$)	52.622 ($p \approx 0$)
OHLCV + Ind. Técnicos	0,861 ($p \approx 0$)	0,842 ($p \approx 0$)	45.426 ($p \approx 0$)
OHLCV + Variáveis calculadas + Ind. Técnicos	0,879 ($p \approx 0$)	0,850 ($p \approx 0$)	49.865 ($p \approx 0$)

Fonte: Elaborada pelo autor (2022)

Figura A.9: PETR4 - Distribuição de RMSE dos modelos LSTM/BiLSTM treinados por cada conjunto de dados de entrada



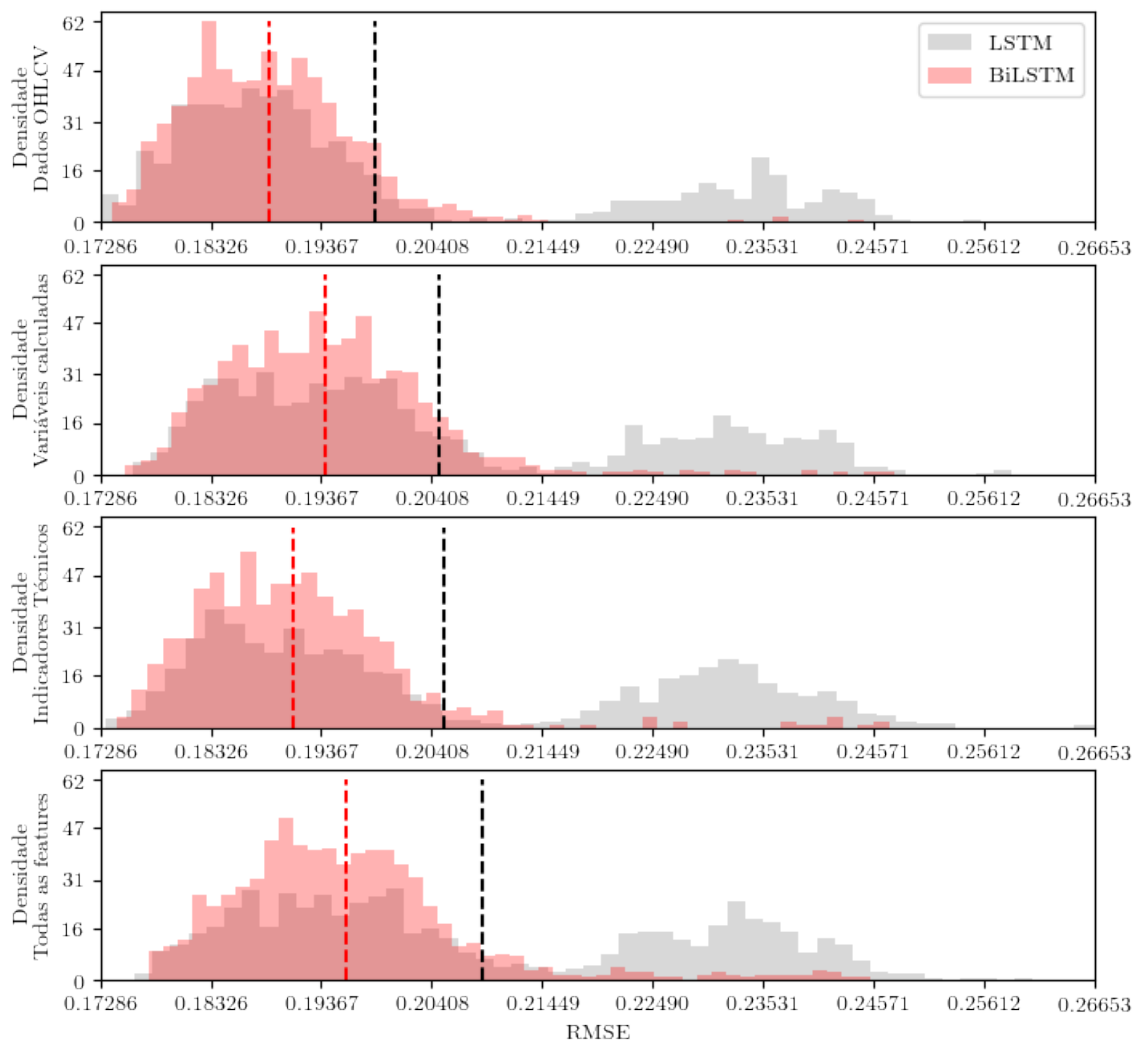
Fonte: Elaborada pelo autor (2022)

Tabela A.10: USIM5 - Testes de normalidade *Shapiro-Wilk* e *Mann-Whitney* entre amostras de modelos LSTM e BiLSTM

Conjunto amostral RMSE USIM5	Teste normalidade Shapiro-Wilk		Teste Wilcoxon Signed-Rank entre modelo LSTM/BiLSTM
	LSTM	BiLSTM	
OHLCV	0,816 ($p \approx 0$)	0,928 ($p \approx 0$)	117.685 ($p \approx 0$)
OHLCV + Var. adicionais	0,893 ($p \approx 0$)	0,928 ($p \approx 0$)	104.917 ($p \approx 0$)
OHLCV + Ind. Técnicos	0,883 ($p \approx 0$)	0,861 ($p \approx 0$)	80.983 ($p \approx 0$)
OHLCV + Variáveis calculadas + Ind. Técnicos	0,919 ($p \approx 0$)	0,895 ($p \approx 0$)	89.033 ($p \approx 0$)

Fonte: Elaborada pelo autor (2022)

Figura A.10: USIM5 - Distribuição de RMSE dos modelos LSTM/BiLSTM treinados por cada conjunto de dados de entrada



Fonte: Elaborada pelo autor (2022)

A.3 Desempenho da aplicação de mecanismo de atenção

A terceira análise consiste em avaliar se o mecanismo de atenção é capaz de melhorar o desempenho de predição do modelo, reduzindo o valor de RMSE.

As Tabelas A.11 a A.15 apresentam os resultados dos testes de normalidade *Shapiro-Wilk* para os conjuntos de amostras de modelos com/sem atenção de cada conjunto de dados de entrada, bem como o teste *Mann-Whitney* entre os modelos com/sem atenção a fim de identificar se as amostras pertencem a uma mesma distribuição.

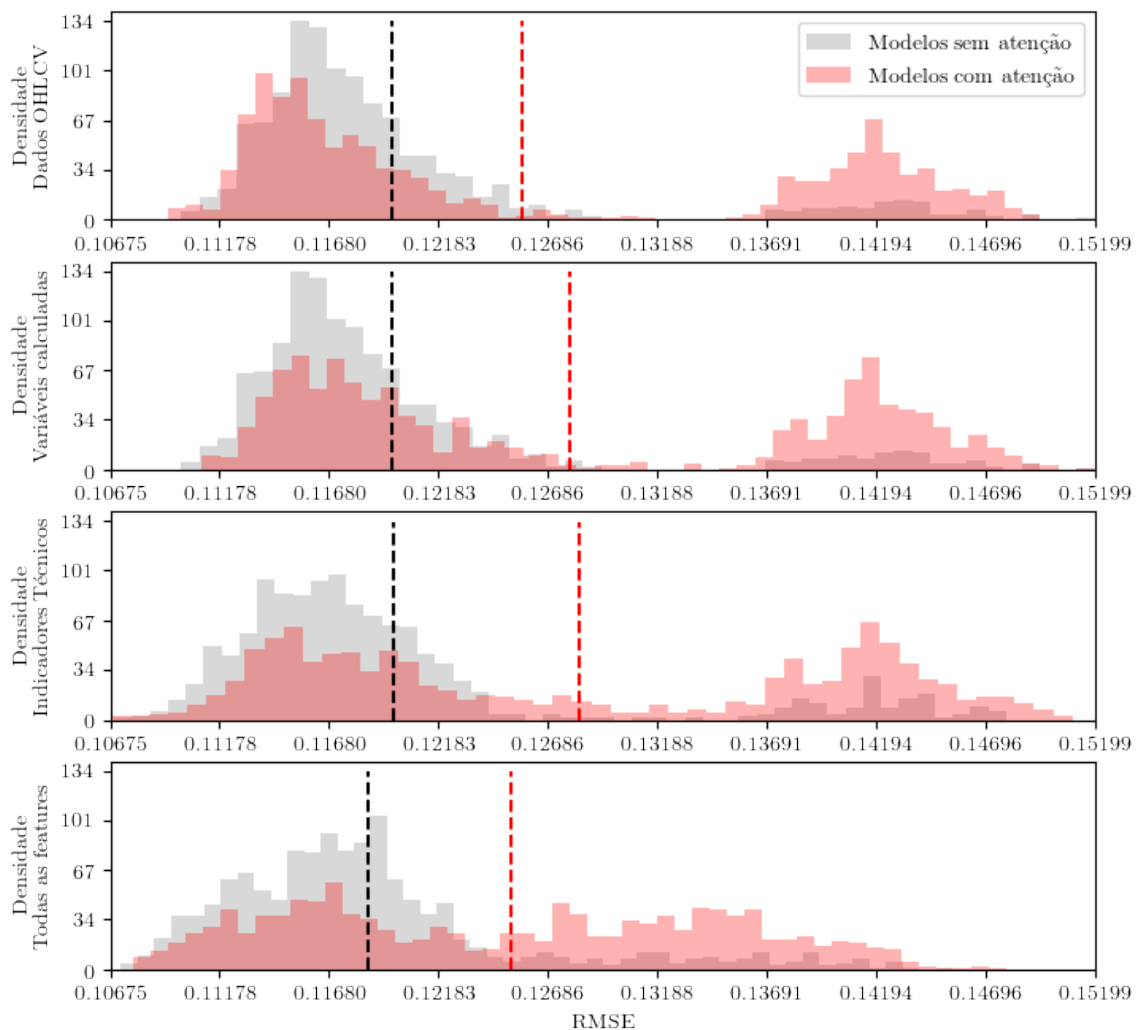
Verifica-se pelos resultados dos testes estatísticos que nenhuma das amostras é oriunda de uma distribuição normal e que as redes sem mecanismo de atenção apresentam melhores resultados de RMSE, quando comparadas a uma rede com mesma estrutura e mecanismo de atenção. Observa-se também que a média do RMSE das amostras dos modelos que não utilizam atenção (linha preta tracejada) foi sempre menor do que a média do RMSE das amostras dos modelos que utilizam atenção (linha tracejada vermelha). Isto demonstra que para o problema de predição de valor de série temporal (problema de regressão), o mecanismo de atenção não parece contribuir para melhorar a performance do modelo. As Figuras A.11 a A.15 apresentam as amostras de RMSE dos modelos com/sem atenção para cada dado de entrada da rede e ativo.

Tabela A.11: ABEV3 - Testes de normalidade *Shapiro-Wilk* e *Mann-Whitney* entre amostras de modelos com/sem atenção

Conjunto amostral RMSE ABEV3	Teste normalidade Shapiro-Wilk		Teste Wilcoxon Signed-Rank entre modelo LSTM/BiLSTM
	Modelos com atenção	Modelos sem atenção	
OHLCV	0,717 ($p \approx 0$)	0,812 ($p \approx 0$)	137,731 ($p \approx 0$)
OHLCV + Var. adicionais	0,717 ($p \approx 0$)	0,844 ($p \approx 0$)	69,421 ($p \approx 0$)
OHLCV + Ind. Técnicos	0,755 ($p \approx 0$)	0,891 ($p \approx 0$)	60,255 ($p \approx 0$)
OHLCV + Variáveis calculadas + Ind. Técnicos	0,871 ($p \approx 0$)	0,955 ($p \approx 0$)	65,855 ($p \approx 0$)

Fonte: Elaborada pelo autor (2022)

Figura A.11: ABEV3 - Distribuição de RMSE dos modelos com/sem mecanismo de atenção treinados por cada conjunto de dados de entrada



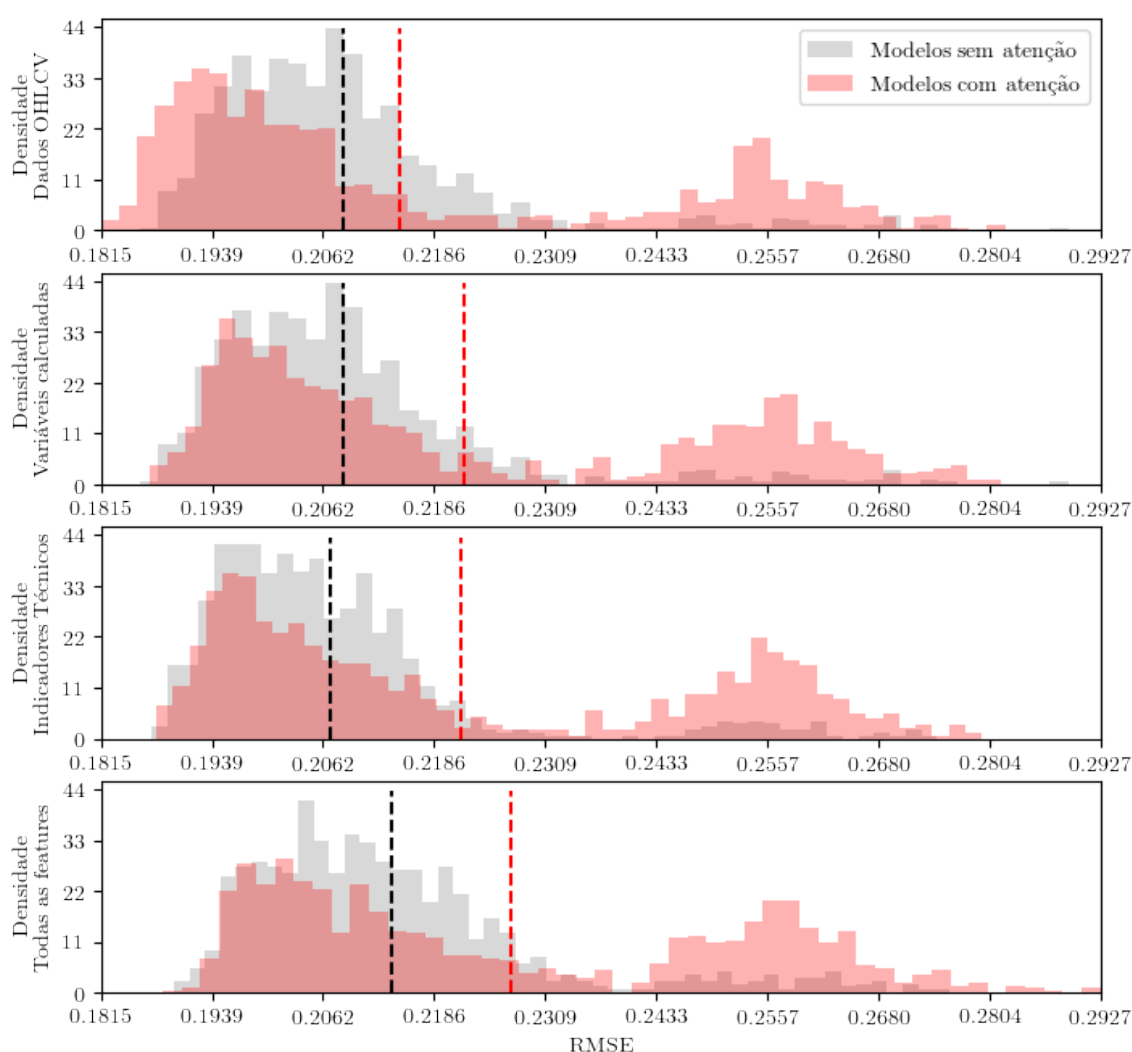
Fonte: Elaborada pelo autor (2022)

Tabela A.12: B3SA3 - Testes de normalidade *Shapiro-Wilk* e *Mann-Whitney* entre amostras de modelos com/sem atenção

Conjunto amostral RMSE B3SA3	Teste normalidade Shapiro-Wilk		Teste Wilcoxon Signed-Rank entre modelo LSTM/BiLSTM
	Modelos com atenção	Modelos sem atenção	
OHLCV	0,822 ($p \approx 0$)	0,833 ($p \approx 0$)	200,229 ($p \approx 0$)
OHLCV + Var. adicionais	0,822 ($p \approx 0$)	0,864 ($p \approx 0$)	109,329 ($p \approx 0$)
OHLCV + Ind. Técnicos	0,784 ($p \approx 0$)	0,860 ($p \approx 0$)	92,418 ($p \approx 0$)
OHLCV + Variáveis calculadas + Ind. Técnicos	0,868 ($p \approx 0$)	0,897 ($p \approx 0$)	95,431 ($p \approx 0$)

Fonte: Elaborada pelo autor (2022)

Figura A.12: B3SA3 - Distribuição de RMSE dos modelos com/sem mecanismo de atenção treinados por cada conjunto de dados de entrada



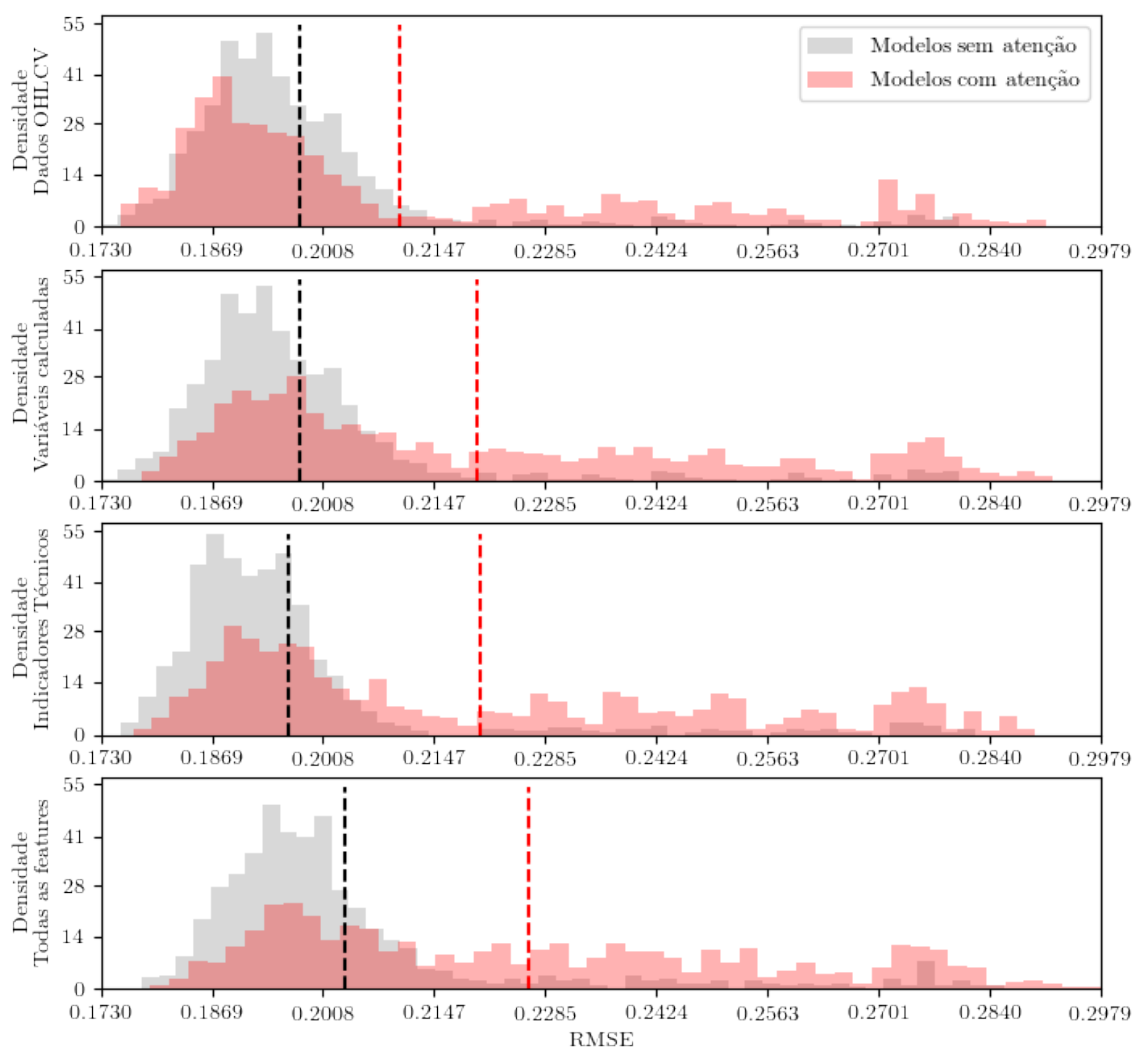
Fonte: Elaborada pelo autor (2022)

Tabela A.13: ITUB4 - Testes de normalidade *Shapiro-Wilk* e *Mann-Whitney* entre amostras de modelos com/sem atenção

Conjunto amostral RMSE ITUB4	Teste normalidade Shapiro-Wilk		Teste Wilcoxon Signed-Rank entre modelo LSTM/BiLSTM
	Modelos com atenção	Modelos sem atenção	
OHLCV	0,700 ($p \approx 0$)	0,834 ($p \approx 0$)	148.937 ($p \approx 0$)
OHLCV + Var. adicionais	0,700 ($p \approx 0$)	0,899 ($p \approx 0$)	53.085 ($p \approx 0$)
OHLCV + Ind. Técnicos	0,647 ($p \approx 0$)	0,894 ($p \approx 0$)	43.328 ($p \approx 0$)
OHLCV + Variáveis calculadas + Ind. Técnicos	0,722 ($p \approx 0$)	0,933 ($p \approx 0$)	49.327 ($p \approx 0$)

Fonte: Elaborada pelo autor (2022)

Figura A.13: ITUB4 - Distribuição de RMSE dos modelos com/sem mecanismo de atenção treinados por cada conjunto de dados de entrada



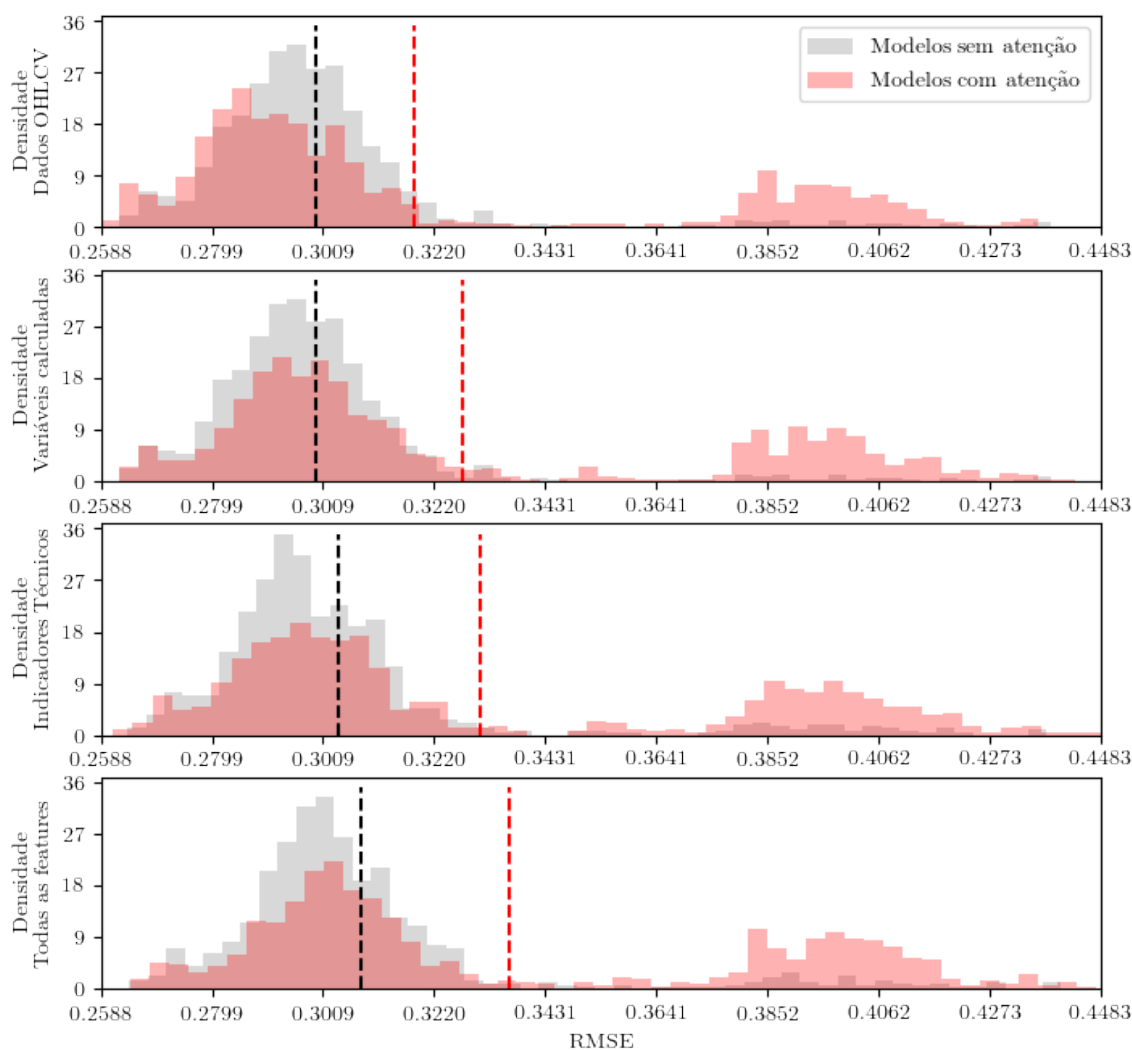
Fonte: Elaborada pelo autor (2022)

Tabela A.14: PETR4 - Testes de normalidade *Shapiro-Wilk* e *Mann-Whitney* entre amostras de modelos com/sem atenção

Conjunto amostral RMSE PETR4	Teste normalidade Shapiro-Wilk		Teste Wilcoxon Signed-Rank entre modelo LSTM/BiLSTM
	Modelos com atenção	Modelos sem atenção	
OHLCV	0,720 ($p \approx 0$)	0,800 ($p \approx 0$)	160.843 ($p \approx 0$)
OHLCV + Var. adicionais	0,720 ($p \approx 0$)	0,838 ($p \approx 0$)	74.487 ($p \approx 0$)
OHLCV + Ind. Técnicos	0,714 ($p \approx 0$)	0,846 ($p \approx 0$)	82.655 ($p \approx 0$)
OHLCV + Variáveis calculadas + Ind. Técnicos	0,731 ($p \approx 0$)	0,861 ($p \approx 0$)	88.738 ($p \approx 0$)

Fonte: Elaborada pelo autor (2022)

Figura A.14: PETR4 - Distribuição de RMSE dos modelos com/sem mecanismo de atenção treinados por cada conjunto de dados de entrada



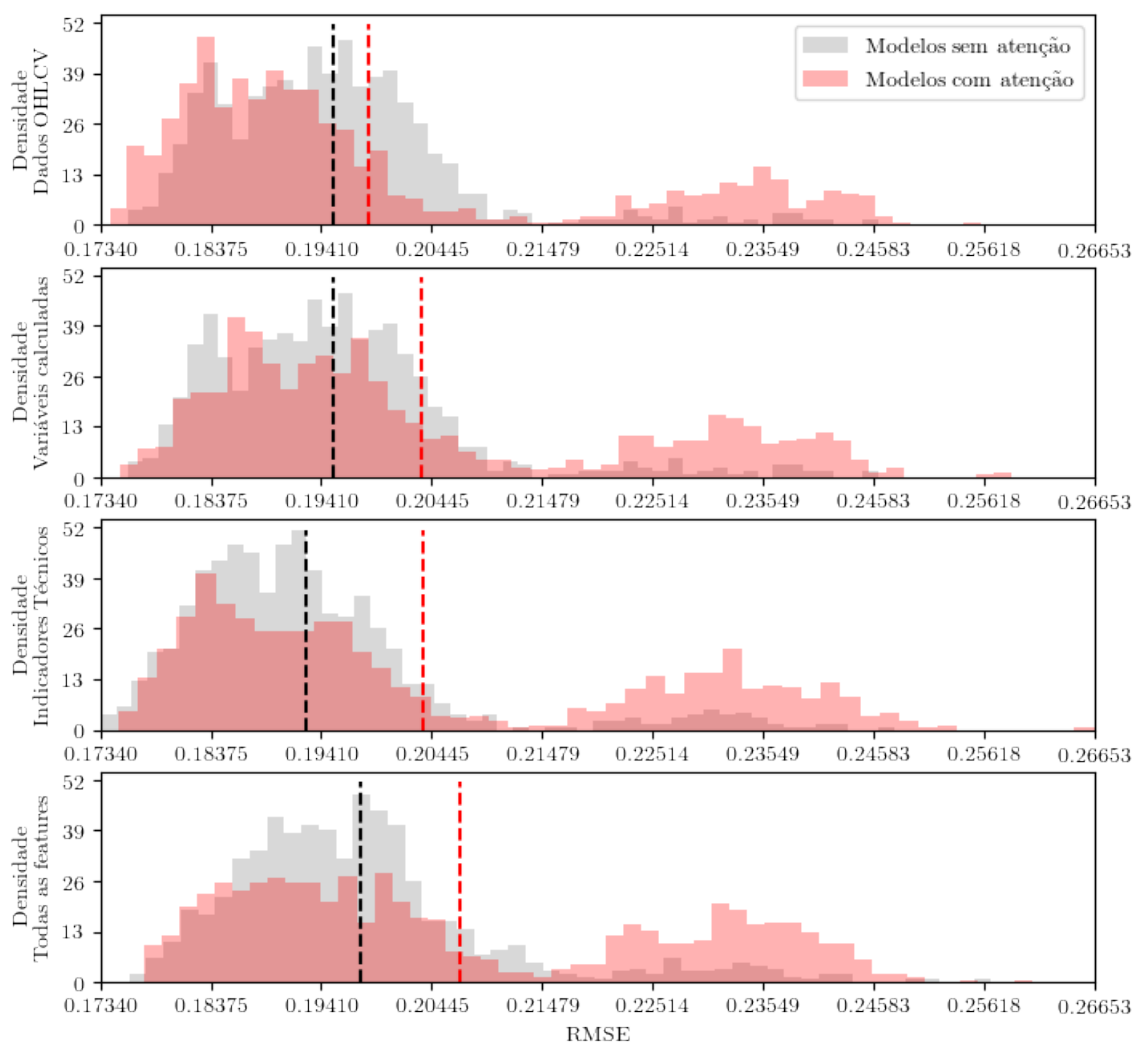
Fonte: Elaborada pelo autor (2022)

Tabela A.15: USIM5 - Testes de normalidade *Shapiro-Wilk* e *Mann-Whitney* entre amostras de modelos com/sem atenção

Conjunto amostral RMSE USIM5	Teste normalidade Shapiro-Wilk		Teste Wilcoxon Signed-Rank entre modelo LSTM/BiLSTM
	Modelos com atenção	Modelos sem atenção	
OHLCV	0,890 ($p \approx 0$)	0,820 ($p \approx 0$)	178.771 ($p \approx 0$)
OHLCV + Var. adicionais	0,890 ($p \approx 0$)	0,881 ($p \approx 0$)	130.524 ($p \approx 0$)
OHLCV + Ind. Técnicos	0,835 ($p \approx 0$)	0,872 ($p \approx 0$)	102.430 ($p \approx 0$)
OHLCV + Variáveis calculadas + Ind. Técnicos	0,883 ($p \approx 0$)	0,907 ($p \approx 0$)	119.114 ($p \approx 0$)

Fonte: Elaborada pelo autor (2022)

Figura A.15: USIM5 - Distribuição de RMSE dos modelos com/sem mecanismo de atenção treinados por cada conjunto de dados de entrada



Fonte: Elaborada pelo autor (2022)

A.4 Impacto dos parâmetros da estrutura do modelo no valor de RMSE

Para identificar a importância e correlação dos parâmetros do modelo no RMSE obtido no conjunto de dados de validação, é realizado o treinamento de uma *random forest* com os parâmetros dos modelos como entrada e o RMSE obtido como saída.

A Tabela A.16 demonstra que o parâmetro mais importante é a o tamanho da janela histórica a ser usada na predição e possui correlação positiva com o valor de RMSE. Em seguida, a quantidade de camadas do modelo é o parâmetro mais importante e nota-se que quanto mais camadas tem o modelo, maior tende a ser o valor do RMSE dada a correlação positiva. Por fim, o parâmetro fator de células tem o menor grau de importância e apresenta correlação pequena e negativa. Isto significa que ao aumentar a quantidade de células por camada do modelo, o valor do RMSE nos dados de validação tende a diminuir.

Tabela A.16: Importância e correlação de parâmetros do modelo no valor de RMSE nos dados de validação

Ativo	Parâmetro	Importância	Correlação
ABEV3	Tamanho da janela	0.729	0.32
	Qtde de camadas	0.227	0.284
	Fator de células	0.043	-0.066
B3SA3	Tamanho da janela	0.785	0.253
	Qtde de camadas	0.165	0.171
	Fator de células	0.05	-0.044
ITUB4	Tamanho da janela	0.737	0.16
	Qtde de camadas	0.187	0.128
	Fator de células	0.076	-0.069
PETR4	Tamanho da janela	0.684	0.197
	Qtde de camadas	0.268	0.234
	Fator de células	0.048	-0.055
USIM5	Tamanho da janela	0.849	0.184
	Qtde de camadas	0.12	0.248
	Fator de células	0.031	-0.025

Fonte: Elaborada pelo autor (2022)

As Tabelas A.17 e A.18 validam a correlação da quantidade de camadas e fator de células na média de RMSE dos modelos treinados. A seguir serão apresentados os gráficos de boxplot do valor de RMSE agrupado por tamanho da janela para cada ativo.

Tabela A.17: Análise agregada do impacto do fator de células na média de RMSE dos modelos

Ativo	Fator de células				
	1	2	3	5	10
ABEV3	0.1237 ± 0.0114	0.1233 ± 0.0113	0.1228 ± 0.0110	0.1226 ± 0.0106	0.1214 ± 0.0097
B3SA3	0.2129 ± 0.0232	0.2144 ± 0.0230	0.2148 ± 0.0229	0.2149 ± 0.0230	0.2149 ± 0.0225
ITUB4	0.2097 ± 0.0288	0.2081 ± 0.0277	0.2079 ± 0.0278	0.2074 ± 0.0269	0.2073 ± 0.0267
PETR4	0.3143 ± 0.0418	0.3143 ± 0.0425	0.3146 ± 0.0420	0.3148 ± 0.0415	0.3148 ± 0.0400
USIM5	0.1986 ± 0.0184	0.1981 ± 0.0180	0.1985 ± 0.0177	0.1982 ± 0.0170	0.1989 ± 0.0168

Fonte: Elaborada pelo autor (2022)

Tabela A.18: Análise agregada do impacto da quantidade de camadas na média de RMSE dos modelos


Ativo	Qtde de camadas		
	1	2	3
ABEV3	0.1191 ± 0.0082	0.1223 ± 0.0107	0.1268 ± 0.0119
B3SA3	0.2086 ± 0.0185	0.2145 ± 0.0230	0.2201 ± 0.0253
ITUB4	0.2012 ± 0.0225	0.2075 ± 0.0274	0.2155 ± 0.0304
PETR4	0.2991 ± 0.0235	0.3162 ± 0.0438	0.3283 ± 0.0476
USIM5	0.1929 ± 0.0123	0.1986 ± 0.0178	0.2038 ± 0.0200

Fonte: Elaborada pelo autor (2022)

A.5 Boxplot de RMSE agrupado por tamanho da janela


As Figuras A.16 a A.20 demonstram que quanto maior o tamanho da janela histórica, maior é a variância do valor de RMSE dos modelos de predição, bem como tende a ser maior a média de RMSE desses modelos.

Figura A.16: ABEV3 - Gráfico de boxplot do valor de RMSE nos dados de validação agrupado por tamanho da janela do modelo




Fonte: Elaborada pelo autor (2022)

Figura A.17: B3SA3 - Gráfico de boxplot do valor de RMSE nos dados de validação agrupado por tamanho da janela do modelo




Fonte: Elaborada pelo autor (2022)

Figura A.18: ITUB4 - Gráfico de boxplot do valor de RMSE nos dados de validação agrupado por tamanho da janela do modelo




Fonte: Elaborada pelo autor (2022)

Figura A.19: PETR4 - Gráfico de boxplot do valor de RMSE nos dados de validação agrupado por tamanho da janela do modelo



Fonte: Elaborada pelo autor (2022)

Figura A.20: USIM5 - Gráfico de boxplot do valor de RMSE nos dados de validação agrupado por tamanho de janela do modelo




Fonte: Elaborada pelo autor (2022)

Apêndice B

Análise estatística dos dados


B.1 Boxplot das variáveis de log-retorno

Figura B.1: ABEV3 - Gráfico boxplot das variáveis de log-retorno




Fonte: Elaborada pelo autor (2022)

Figura B.2: B3SA3 - Gráfico boxplot das variáveis de log-retorno




Fonte: Elaborada pelo autor (2022)

Figura B.3: ITUB4 - Gráfico boxplot das variáveis de log-retorno




Fonte: Elaborada pelo autor (2022)

Figura B.4: PETR4 - Gráfico boxplot das variáveis de log-retorno



Fonte: Elaborada pelo autor (2022)


Figura B.5: USIM5 - Gráfico boxplot das variáveis de log-retorno



Fonte: Elaborada pelo autor (2022)


B.2 Mapas de calor da análise de correlação cruzada

Figura B.6: ABEV3 - Mapa de calor das variáveis de log-retorno




Fonte: Elaborada pelo autor (2022)

Figura B.7: B3SA3 - Mapa de calor das váriaveis de log-retorno




Fonte: Elaborada pelo autor (2022)

Figura B.8: ITUB4 - Mapa de calor das váriaveis de log-retorno




Fonte: Elaborada pelo autor (2022)

Figura B.9: PETR4 - Mapa de calor das variáveis de log-retorno



Fonte: Elaborada pelo autor (2022)

Figura B.10: USIM5 - Mapa de calor das variáveis de log-retorno

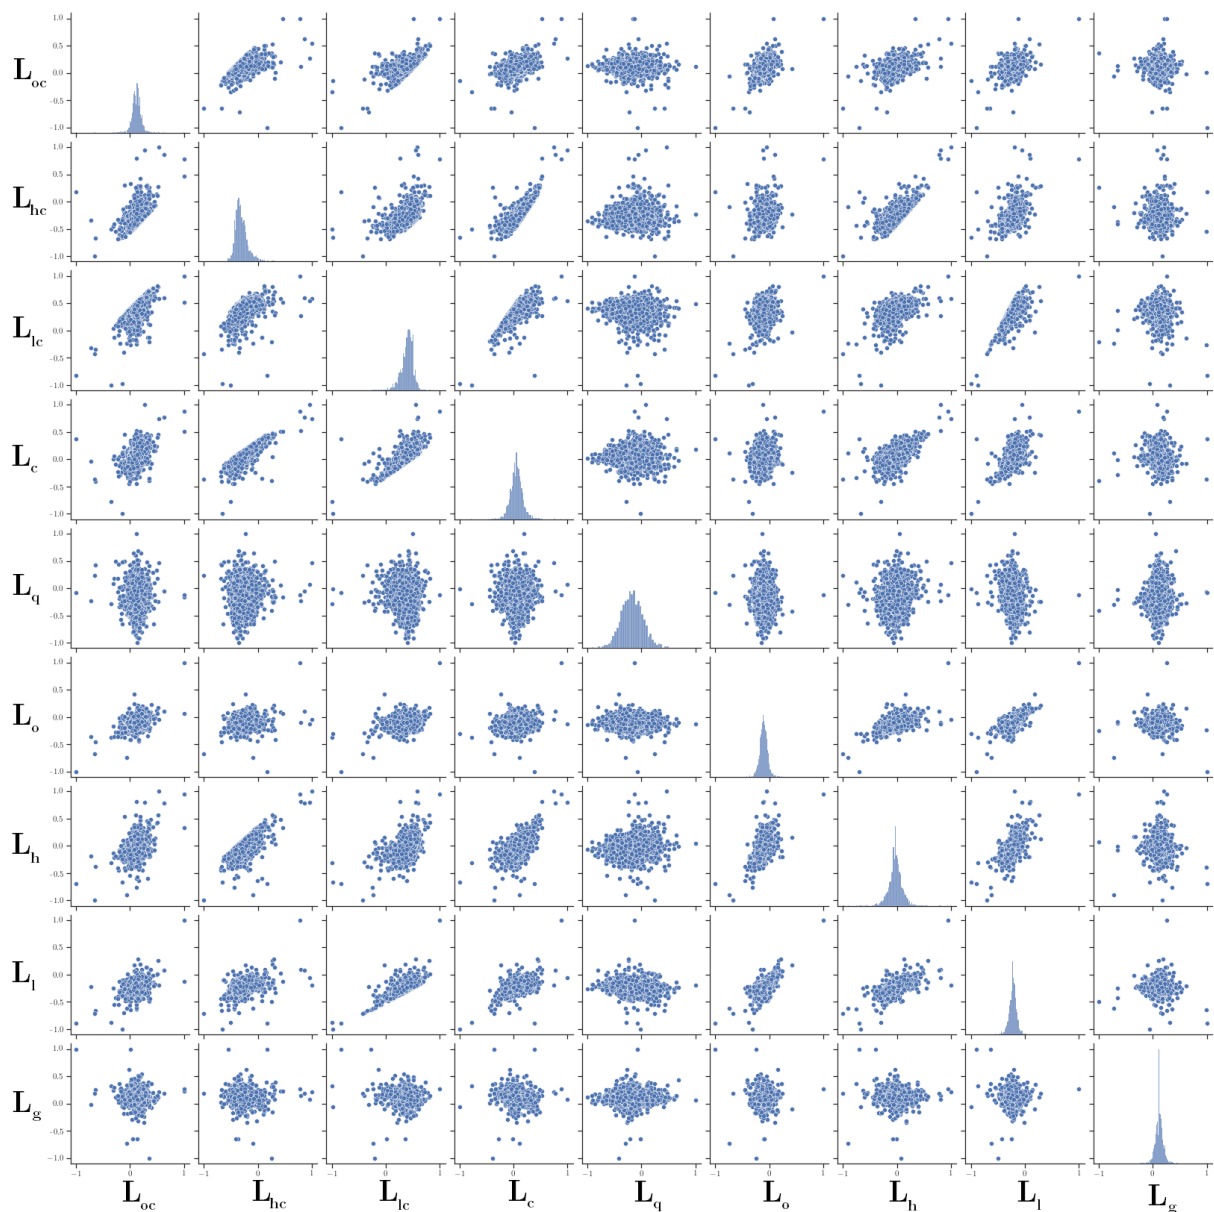


Fonte: Elaborada pelo autor (2022)

B.3 Gráficos de distribuição e dispersão

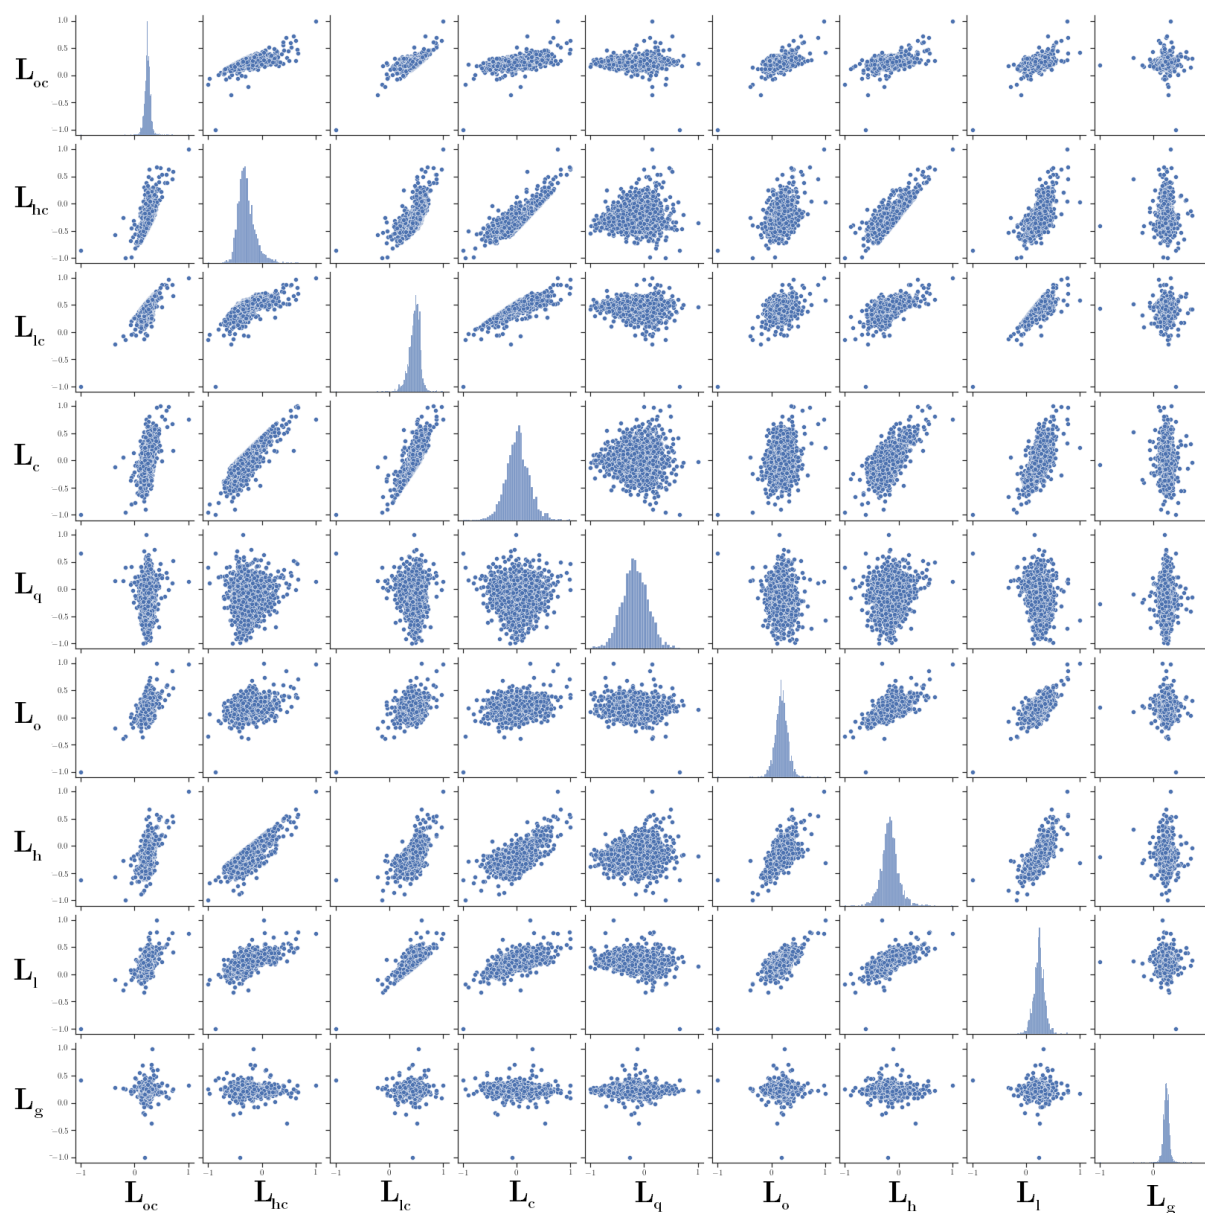
Para o log-retorno do valor máximo em relação ao fechamento anterior (L_{hc}), os gráficos sugeriram haver uma relação mais linear com as variáveis L_{oc} , L_{lc} , L_c , L_h e L_l . Já o log-retorno do valor mínimo em relação ao fechamento anterior (L_{lc}) possui relação linear com as variáveis L_{oc} , L_{hc} , L_c , L_h e L_l . A informação de volume negociado parece não ter relação linear com nenhuma variável.

Figura B.11: ABEV3 - Gráfico de distribuição e dispersão das variáveis de log-retorno



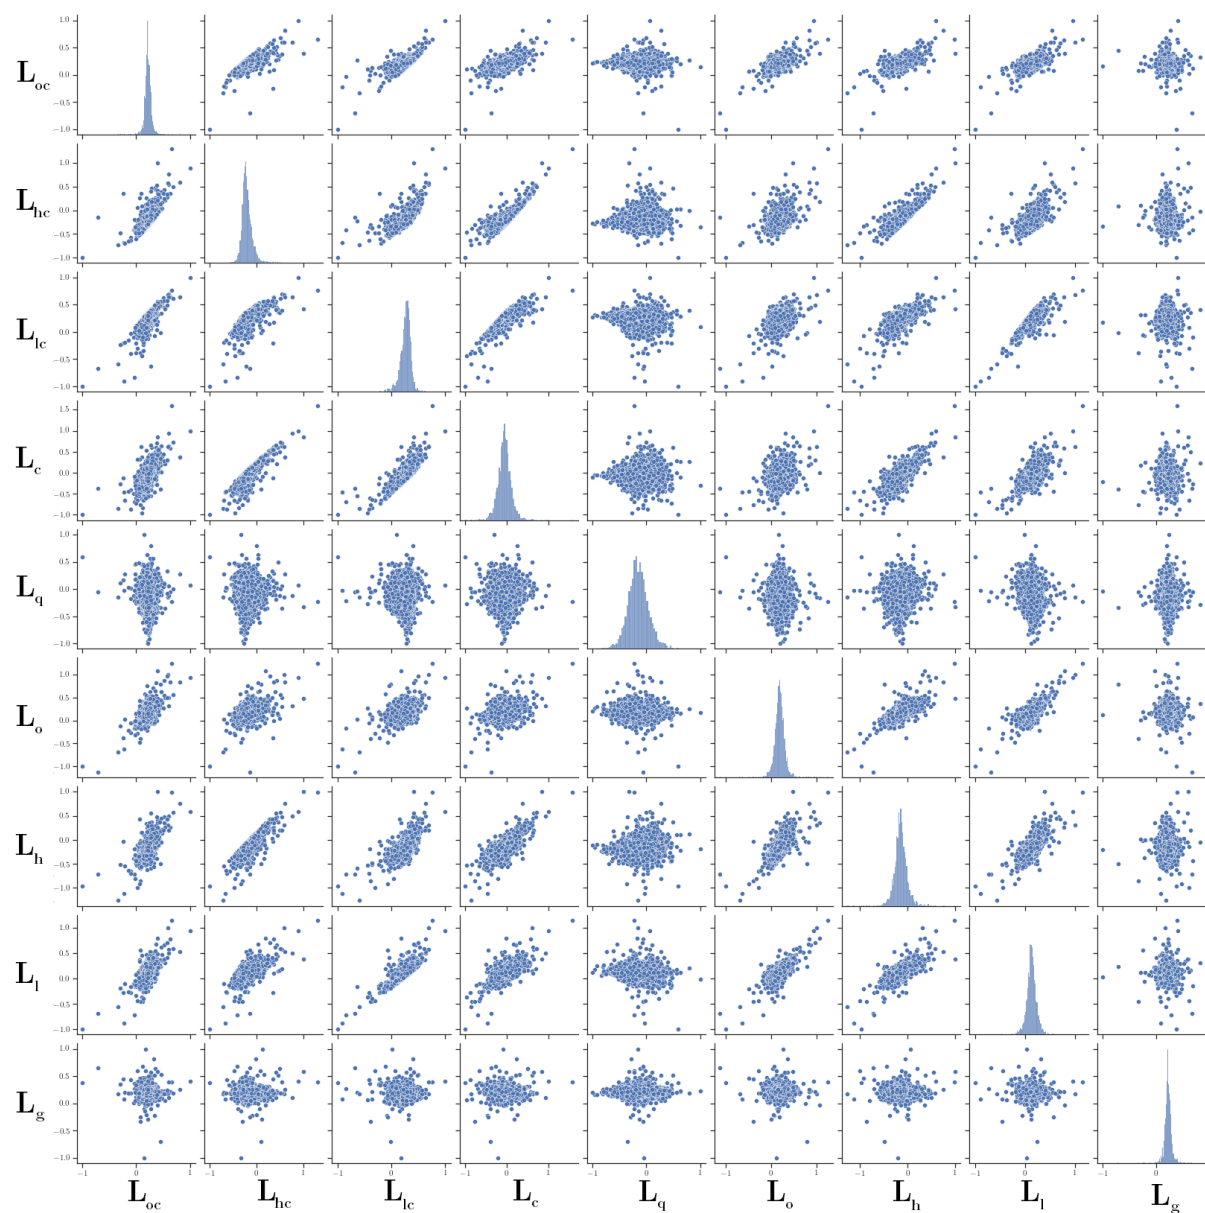
Fonte: Elaborada pelo autor (2022)

Figura B.12: B3SA3 - Gráfico de distribuição e dispersão das variáveis de log-retorno



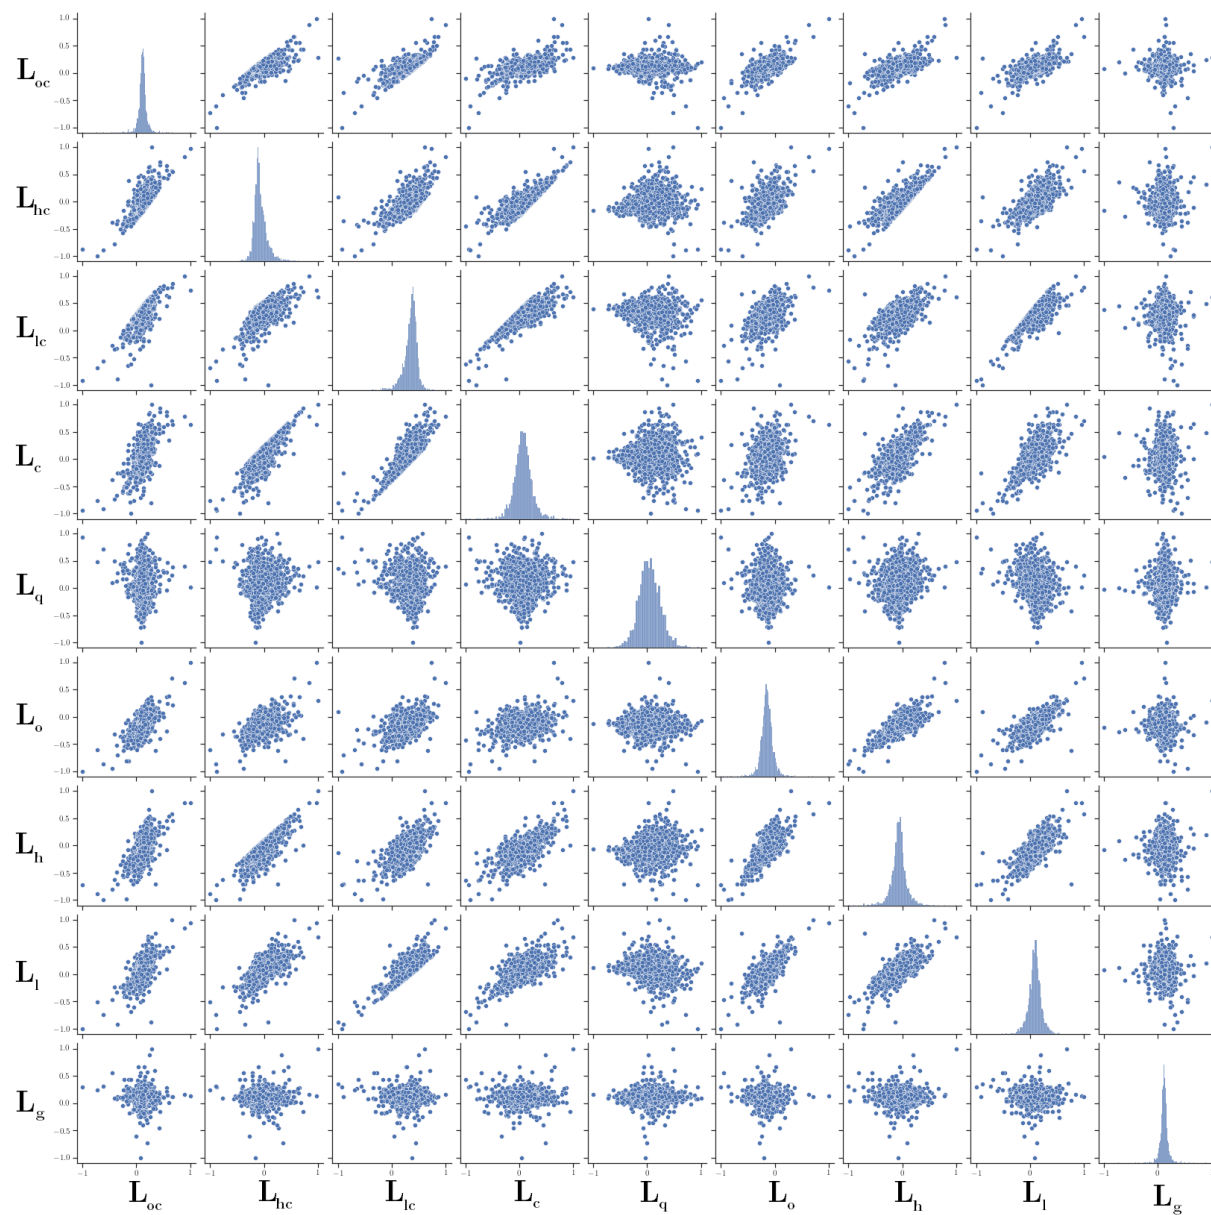
Fonte: Elaborada pelo autor (2022)

Figura B.13: ITUB4 - Gráfico de distribuição e dispersão das variáveis de log-retorno



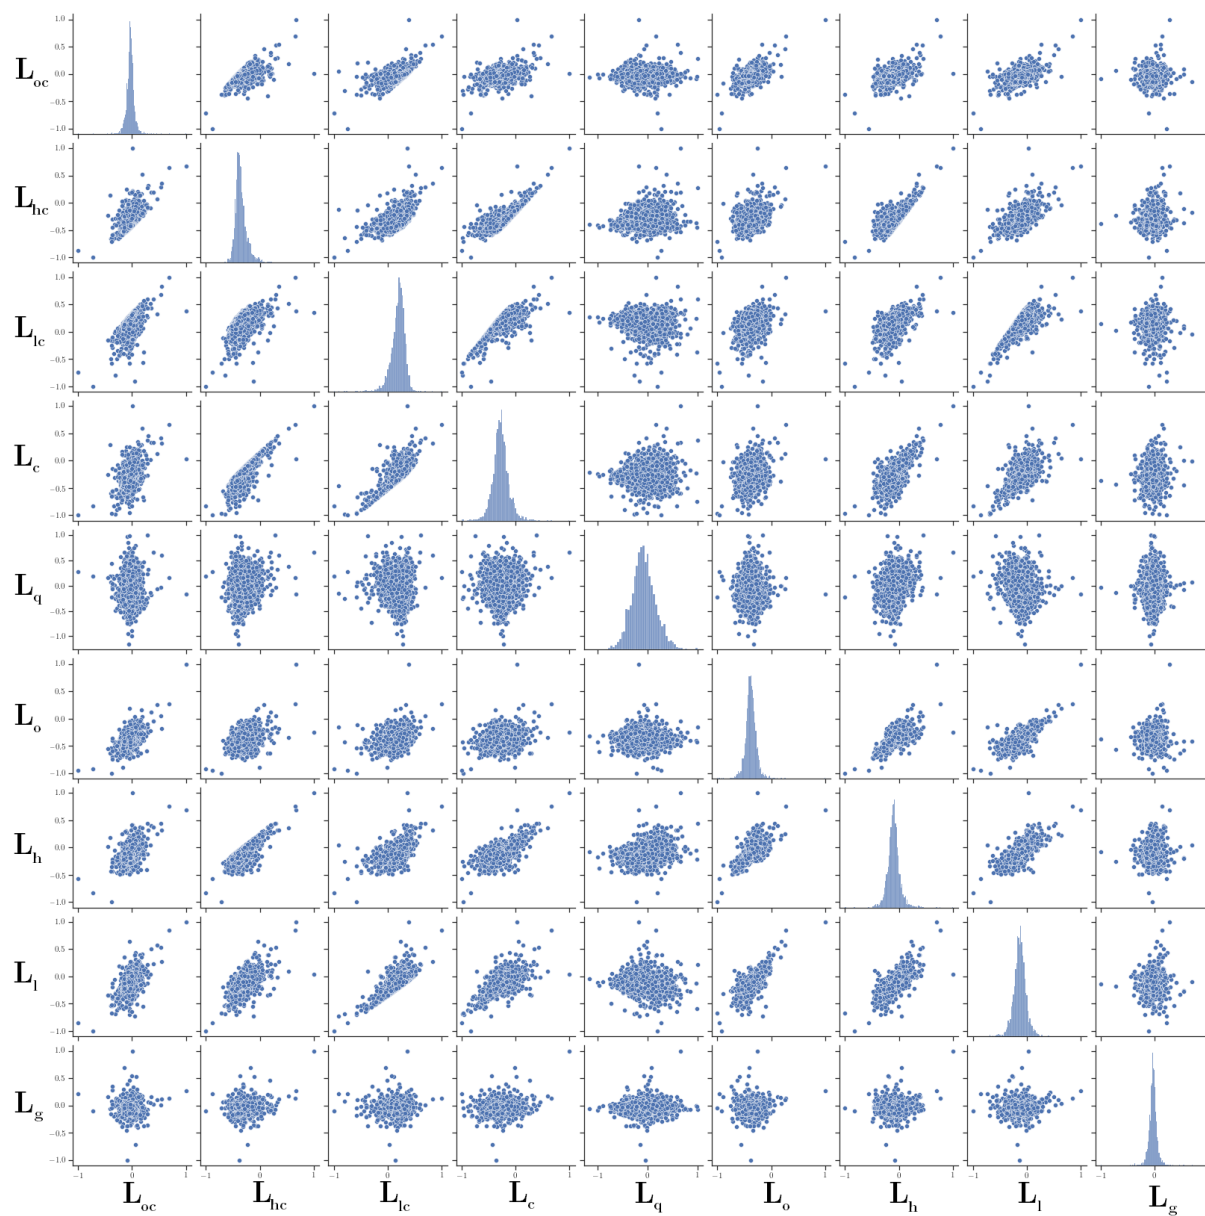
Fonte: Elaborada pelo autor (2022)

Figura B.14: PETR4 - Gráfico de distribuição e dispersão das variáveis de log-retorno



Fonte: Elaborada pelo autor (2022)


Figura B.15: USIM5 - Gráfico de distribuição e dispersão das variáveis de log-retorno



Fonte: Elaborada pelo autor (2022)

B.4 Distribuição de retornos percentuais dos valores máximos e mínimos em relação à abertura


Figura B.16: ABEV3 - Distribuição dos retornos percentuais dos valores máximos e mínimos em relação ao preço de abertura do dia



Fonte: Elaborada pelo autor (2022)


B.5 Distribuição de retornos percentuais do valor máximo em relação ao mínimo do dia

Figura B.17: B3SA3 - Distribuição dos retornos percentuais dos valores máximos e mínimos em relação ao preço de abertura do dia




Fonte: Elaborada pelo autor (2022)

Figura B.18: ITUB4 - Distribuição dos retornos percentuais dos valores máximos e mínimos em relação ao preço de abertura do dia




Fonte: Elaborada pelo autor (2022)

Figura B.19: PETR4 - Distribuição dos retornos percentuais dos valores máximos e mínimos em relação ao preço de abertura do dia




Fonte: Elaborada pelo autor (2022)

Figura B.20: USIM5 - Distribuição dos retornos percentuais dos valores máximos e mínimos em relação ao preço de abertura do dia




Fonte: Elaborada pelo autor (2022)

Figura B.21: ABEV3 - Distribuição do retorno percentual do valor máximo em relação ao valor mínimo do dia




Fonte: Elaborada pelo autor (2022)

Figura B.22: B3SA3 - Distribuição do retorno percentual do valor máximo em relação ao valor mínimo do dia




Fonte: Elaborada pelo autor (2022)

Figura B.23: ITUB4 - Distribuição do retorno percentual do valor máximo em relação ao valor mínimo do dia




Fonte: Elaborada pelo autor (2022)

Figura B.24: PETR4 - Distribuição do retorno percentual do valor máximo em relação ao valor mínimo do dia



Fonte: Elaborada pelo autor (2022)

Figura B.25: USIM5 - Distribuição do retorno percentual do valor máximo em relação ao valor mínimo do dia



Fonte: Elaborada pelo autor (2022)

Apêndice C

Gráficos dos cenários para backtesting

Figura C.1: ABEV3 - Janela temporal de backtesting



Fonte: Elaborada pelo autor (2022)

Figura C.2: B3SA3 - Janela temporal de backtesting



Fonte: Elaborada pelo autor (2022)

Figura C.3: ITUB4 - Janela temporal de backtesting



Fonte: Elaborada pelo autor (2022)

Figura C.4: PETR4 - Janela temporal de backtesting



Fonte: Elaborada pelo autor (2022)

Figura C.5: USIM5 - Janela temporal de backtesting



Fonte: Elaborada pelo autor (2022)