

UNIVERSIDADE FEDERAL DE SÃO CARLOS  
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA  
DEPARTAMENTO DE ESTATÍSTICA

**Análise das ações da Magazine Luiza (Magalu) pré e  
pós aquisição da Kabum.**

**Ricardo Augusto Octaviano**

**Trabalho de Conclusão de Curso**



UNIVERSIDADE FEDERAL DE SÃO CARLOS  
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA  
DEPARTAMENTO DE ESTATÍSTICA

Análise das ações da Magazine Luiza (Magalu)  
pré e pós aquisição da Kabum.

**Ricardo Augusto Octaviano**

**Orientadora: Maria Sílvia de Assis Moura**

Trabalho de Conclusão de Curso apresentado  
como parte dos requisitos para obtenção do  
título de Bacharel em Estatística.

**São Carlos**

**Fevereiro de 2025**



FEDERAL UNIVERSITY OF SÃO CARLOS  
EXACT AND TECHNOLOGY SCIENCES CENTER  
DEPARTMENT OF STATISTICS

Analysis of Magazine Luiza's (Magalu) stock  
before and after the acquisition of Kabum.

**Ricardo Augusto Octaviano**

**Advisor: Maria Sílvia de Assis Moura**

Bachelors dissertation submitted to the Department of Statistics, Federal University of São Carlos - DEs-UFSCar, in partial fulfillment of the requirements for the degree of Bachelor in Statistics.

São Carlos  
January 2025



Ricardo Augusto Octaviano

Análise das ações da Magazine Luiza (Magalu)  
pré e pós aquisição da Kabum.

Este exemplar corresponde à redação final do trabalho de conclusão de curso devidamente corrigido e defendido por nome do(a) aluno(a) e aprovado pela banca examinadora.

Aprovado em dia de mês de ano

Banca Examinadora:

- Maria Sílvia de Assis Moura
- Marcio Alves Diniz
- Michel Helcias Montoril



*Aos meus familiares e amigos por todo suporte.*



# Agradecimentos

“ Agradeço, primeiramente, à minha orientadora pela paciência e pelas explicações diante de todas as dúvidas que tive ao longo do trabalho.

Aos meus familiares, pelo apoio constante durante toda essa jornada.

A minha companheira, pela paciência e apoio nos momentos difíceis.

Aos meus amigos, pela companhia e pelos momentos de diversão que tornaram essa caminhada mais leve.

A todos vocês, meu sincero obrigado!”



*“Quanto mais aumenta nosso conhecimento, mais evidente fica nossa ignorância.”*

(John F. Kennedy)



# Resumo

O presente trabalho propõe uma análise das ações da Magazine Luiza no contexto da aquisição da Kabum, buscando compreender as variações nos preços de fechamento pré e pós a transação. O estudo se baseará na implementação de um modelo *GARCH* ou *ARCH*, visando identificar padrões de volatilidade e avaliar se houve alterações significativas nas características do comportamento dos preços. A escolha desses modelos se justifica pela capacidade de capturar a volatilidade nos dados temporais, tornando-os adequados para analisar mudanças na variabilidade ao longo do tempo.

Os resultados indicam que o comportamento das ações da Magalu apresentaram padrões distintos nos períodos analisados. Antes da aquisição, o modelo *GARCH*(1,1) mostrou-se adequado para capturar a volatilidade, enquanto, após a aquisição, a estrutura da volatilidade tornou-se mais complexa, sugerindo que fatores externos podem ter influenciado a dinâmica dos retornos. O declínio nos preços das ações após a transação pode estar relacionado a variáveis não diretamente contempladas neste estudo, como condições macroeconômicas ou mudanças na percepção dos investidores.

**Palavras-chave:** *Aquisição, ARCH, GARCH, Kabum, Magazine Luiza, Modelagem Financeira, Volatilidade.*



# Abstract

The present work proposes an analysis of Magazine Luiza's stocks in the context of the acquisition of Kabum, seeking to understand the variations in closing prices before and after the transaction. The study will be based on the implementation of a *GARCH* or *ARCH* model, aiming to identify volatility patterns and assess whether there have been significant changes in price behavior characteristics. The choice of these models is justified by their ability to capture volatility in time series data, making them suitable for analyzing changes in variability over time.

The results indicate that Magalu's stock behavior exhibited distinct patterns in the analyzed periods. Before the acquisition, the *GARCH*(1,1) model was adequate for capturing volatility, whereas after the acquisition, the volatility structure became more complex, suggesting that external factors may have influenced the dynamics of returns. The decline in stock prices following the transaction may be related to variables not directly considered in this study, such as macroeconomic conditions or changes in investor perception.

**Keywords:** *Acquisition, ARCH, GARCH, Kabum, Magazine Luiza, Financial Modeling, Volatility.*



# Lista de Figuras

3.1	Preço de fechamento Magalu. . . . .	37
3.2	Log retorno do preço de fechamento Magalu. . . . .	38
3.3	Preço de fechamento Magalu antes da compra. . . . .	39
3.4	Log retorno do preço de fechamento Magalu antes da compra. . . . .	40
3.5	Função de Autocorrelação para o log-retorno antes da compra. . . . .	40
3.6	Função de Autocorrelação Parcial para o log-retorno antes da compra. . . .	41
3.7	Função de Autocorrelação do quadrado do log-retorno para antes da compra.	41
3.8	Preço de fechamento Magalu após a compra. . . . .	42
3.9	Função de Autocorrelação para o log-retorno depois da compra. . . . .	43
3.10	Função de Autocorrelação Parcial para o log-retorno depois da compra. . .	43
3.11	Função de Autocorrelação do quadrado do log-retorno para depois da compra.	44
3.12	Função de Autocorrelação para os resíduos do Modelo GARCH(1,1) no período anterior a compra. . . . .	48
3.13	Função de Autocorrelação Parcial para os resíduos do Modelo GARCH(1,1) no período anterior a compra. . . . .	48
3.14	Função de Autocorrelação dos resíduos ao Quadrado para o Modelo GARCH(1,1) no período anterior a compra. . . . .	49
3.15	Função de Autocorrelação para para os resíduos do Modelo GARCH(1,1) no período posterior a compra. . . . .	52
3.16	Função de Autocorrelação Parcial para para os resíduos do Modelo GARCH(1,1) no período posterior a compra. . . . .	53
3.17	Função de Autocorrelação dos resíduos ao Quadrado para o Modelo GARCH(1,1) no período posterior a compra. . . . .	54



# Lista de Tabelas

3.1	Estatísticas Descritivas dos preços de fechamento da Magalu . . . . .	36
3.2	Comparação dos Critérios AIC e BIC para os modelos antes da compra . .	45
3.3	P-valor do Teste de Ljung-Box para antes da compra . . . . .	49
3.4	Comparação dos Critérios AIC e BIC para os modelos depois da compra .	50
3.5	P-valor do Teste de Ljung-Box para após a compra . . . . .	54



# Sumário

<b>1</b>	<b>Introdução</b>	<b>23</b>
<b>2</b>	<b>Retornos, Volatilidade</b>	<b>25</b>
2.1	Retornos . . . . .	25
2.2	Volatilidade . . . . .	27
<b>3</b>	<b>Análise das Séries</b>	<b>29</b>
3.1	Modelo $ARCH(q)$ . . . . .	29
3.2	Modelo $GARCH(p, q)$ . . . . .	31
3.3	Teste Dickey-Fuller Aumentado (ADF) . . . . .	32
3.3.1	Implementação no R . . . . .	32
3.3.2	Formulação e Hipóteses . . . . .	32
3.3.3	Interpretação e Conclusão . . . . .	33
3.4	O Critério de Informação de Akaike (AIC) . . . . .	33
3.5	O Critério de Informação Bayesiano (BIC) . . . . .	34
3.6	Teste de Ljung-Box . . . . .	35
3.7	Magazine Luiza (MGLU3.SA) . . . . .	35
3.7.1	Magazine Luiza antes da compra da Kabum . . . . .	39
3.7.2	Magazine Luiza após a compra da Kabum . . . . .	42
3.8	Modelagem $GARCH$ para Antes da Compra . . . . .	45
3.8.1	Especificação do Modelo $GARCH(1, 1)$ para antes da compra . . . . .	46
3.8.2	Adequação do Modelo $GARCH(1, 1)$ para o período antes da compra . . . . .	48
3.9	Modelagem $GARCH$ para Depois da Compra . . . . .	50
3.9.1	Especificação do Modelo $GARCH(1, 1)$ para o período pós-compra . . . . .	51
3.9.2	Adequação do Modelo $GARCH(1, 1)$ para o período depois da compra . . . . .	52
3.9.3	Análise Comparativa . . . . .	55

4 Conclusão	57
Referências Bibliográficas	58
A Códigos	61

# Capítulo 1

## Introdução

Este estudo visa analisar as variações na volatilidade das ações da Magalu em relação ao preço de fechamento antes e depois da aquisição da Kabum. Os resultados pretendem contribuir para uma compreensão mais aprofundada dos padrões em séries financeiras, fornecendo informações valiosas para aprimorar a precisão das previsões e estratégias de investimento.

O mercado de ações é um importante indicador de situações econômicas, refletindo a confiança dos investidores e as expectativas sobre o desempenho das empresas. Portanto, a análise da volatilidade das ações da Magalu pode fornecer insights valiosos sobre a reação do mercado a eventos específicos.

A motivação para a realização deste estudo surgiu do interesse em entender como um evento corporativo significativo, como a aquisição da Kabum pela Magalu, pode afetar o comportamento das ações no mercado financeiro. Além de ser um tema de grande relevância, investigar tais impactos proporciona insights sobre a relação entre eventos específicos e volatilidade, ajudando a esclarecer o comportamento das séries financeiras. A análise detalhada da volatilidade não apenas ajuda na compreensão do impacto de eventos específicos, mas também oferece suporte para a formulação de estratégias de investimento mais eficazes e assertivas.

Os modelos utilizados neste trabalho para analisar a volatilidade das séries financeiras são o *GARCH* e o *ARCH*. Esses modelos podem ser empregados para capturar a dinâmica da volatilidade em séries temporais financeiras. A base teórica e prática sobre esses modelos foi essencialmente obtida a partir de duas fontes referenciadas: ([Morettin e Tolo, 2006](#)) e ([Tsay, 2014](#)).

O objetivo deste estudo é obter informações sobre os efeitos da aquisição da Kabum

no comportamento das ações da Magalu e verificar se há diferenças significativas antes e depois da compra. Esses resultados podem oferecer contribuições valiosas para a análise de eventos corporativos e sua relação com a dinâmica do mercado financeiro.

Este trabalho está estruturado da seguinte maneira: No capítulo dois, falamos sobre fatos estilizados, volatilidade e calculamos retornos em séries financeiras. No capítulo três, fazemos uma análise completa da série. No capítulo quatro, apresentamos a conclusão do trabalho.

# Capítulo 2

## Retornos, Volatilidade

Neste capítulo, serão apresentadas as definições e fórmulas fundamentais para o cálculo dos retornos simples e logarítmicos, destacando a importância do log-retorno na modelagem financeira devido às suas propriedades estatísticas. Além disso, discutiremos os principais fatos estilizados observados nos retornos financeiros. Por fim, mostraremos as definições de volatilidade.

### 2.1 Retornos

Medida normalmente utilizada para o estudo do desempenho de ativos financeiros ao longo do tempo. Calculamos o retorno para verificar a variação de um ativo em certo intervalo de tempo.

Assim, podemos calcular a variação de preço  $P_t$ , entre os períodos  $t$  e  $t - 1$  como:

$$\Delta P_t = P_t - P_{t-1}. \quad (2.1)$$

Da mesma forma, a taxa de retorno  $R_t$  é calculada como:

$$R_t = \frac{P_t - P_{t-1}}{P_{t-1}}. \quad (2.2)$$

sabendo que:

$$P_t - P_{t-1} = \Delta P_t, \quad (2.3)$$

podemos dizer que:

$$R_t = \frac{\Delta P_t}{P_{t-1}}. \quad (2.4)$$

Porém, para a utilização em Séries Financeiras, utilizamos normalmente o log-retorno  $X_t$ , que é calculado como:

$$X_t = \log \frac{P_t}{P_{t-1}}. \quad (2.5)$$

Seguindo como (Morettin e Tolo, 2006) nos indica, denotando  $p_t = \log P_t$  com logaritmo de base  $e$ , temos o log-retorno  $X_t$ , na seguinte forma:

$$X_t = p_t - p_{t-1}. \quad (2.6)$$

A equação 2.6 será empregada ao longo deste trabalho, onde  $X_t$  (log-retorno) será designado como retorno para simplificar a comunicação.

O uso desses retornos, em vez de preços, na prática financeira, é definido por (Morettin e Tolo, 2006) por razões estatísticas. Os retornos são independentes de escala, facilitando comparações entre períodos, além de apresentarem estacionariedade.

Os fatos estilizados relacionados aos retornos financeiros são características estatísticas comuns observadas em séries financeiras, independentemente de mercado, tempo ou ativo analisado.

Sendo eles:

- **Não-Autocorrelação nos Retornos:** Os retornos financeiros são, em sua maioria, fracamente autocorrelacionados, o que indica que os valores passados não possuem forte influência direta sobre os valores futuros.
- **Autocorrelação nos Quadrados dos Retornos:** Os quadrados dos retornos exibem autocorrelação significativa com uma queda gradual com o aumento das defasagens.
- **Heterocedasticidade Condicional:** Os retornos financeiros apresentam períodos de alta oscilação seguidos de momentos mais estáveis. Isso significa que a variabilidade dos dados não é constante ao longo do tempo, o que contradiz modelos que consideram a volatilidade constante.
- **Distribuição dos Retornos:** A distribuição dos retornos apresenta caudas mais pesadas do que a distribuição normal, caracterizando-se por um comportamento leptocúrtico e aproximadamente simétrico.

- **Não-Linearidade:** Algumas séries de retornos apresentam comportamento não-linear, ou seja, respondem de maneira diferente a choques de diferentes magnitudes ou direções.

## 2.2 Volatilidade

A volatilidade é a variação de um ativo financeiro ao longo do tempo. Como descrita por (Morettin e Tolo, 2006), é a variância condicional, associada aos retornos. Uma alta volatilidade indica que os valores estão se movendo rapidamente e variando consideravelmente, enquanto uma baixa volatilidade sugere movimentos mais estáveis e previsíveis.

Existem três principais abordagens para explicar a volatilidade, sendo elas:

- **Volatilidade Realizada:** Envolve modelar diretamente a volatilidade dos retornos da série, utilizando modelos como *GARCH*, permitindo uma compreensão mais detalhada das flutuações de volatilidade ao longo do tempo;
- **Volatilidade Implícita:** Está relacionada às expectativas do mercado sobre a variabilidade futura dos preços de um ativo, portanto, reflete as expectativas do mercado sobre o futuro.
- **Volatilidade Histórica:** Refere-se à medida de variação dos retornos de um ativo em um período passado específico.

Podemos calcular a volatilidade para cada instante  $t$ , utilizando a média dos  $k$  retornos passados. Obtendo,

$$v_t = \left[ \frac{1}{k} \sum_{j=0}^{k-1} |r_{t-j}|^m \right]^{1/m}, \quad (2.7)$$

onde:

- $v_t$  volatilidade no tempo  $t$
- $r_{t-j}$  log-retorno no tempo  $t - j$ ,
- $m$  constante arbitrária,



# Capítulo 3

## Análise das Séries

Este capítulo tem como objetivo investigar a dinâmica da volatilidade das ações da Magazine Luiza (Magalu) antes e após a aquisição da Kabum, utilizando técnicas de modelagem *ARCH* ou *GARCH*. Inicia-se com uma análise exploratória das séries de preços de fechamento, aplicando transformações para estabilizar a variância e garantir estacionariedade, verificado pelo teste Dickey-Fuller Aumentado (ADF). Em seguida, são ajustados modelos para cada período, avaliando a significância dos parâmetros e a adequação dos modelos por meio do teste de Ljung-Box e análise de resíduos. Por fim, compara-se os padrões de volatilidade entre os períodos, buscando mudanças estruturais decorrentes da aquisição.

### 3.1 Modelo *ARCH*( $q$ )

O modelo *ARCH* (Autorregressivo de Heterocedasticidade Condicional), proposto por Robert Engle em 1982 (Morettin e Tolo, 2006), é um pilar na análise de séries temporais financeiras. Esse modelo aborda a heterocedasticidade, característica marcante nos retornos de ativos financeiros, onde períodos alternados de alta e baixa volatilidade são comuns. Essa capacidade de modelar a variância condicional dos retornos como uma função das realizações passadas torna o *ARCH* uma ferramenta essencial para a gestão de riscos e as decisões de investimento.

Segundo (Morettin e Tolo, 2006), o modelo é definido pelas seguintes equações:

$$X_t = \sqrt{h_t} \epsilon_t, \quad (3.1)$$

$$h_t = \omega + \alpha_1 X_{t-1}^2 + \cdots + \alpha_q X_{t-q}^2, \quad (3.2)$$

onde:

- $X_t$  representa o log-retorno do ativo no tempo  $t$ ,
- $h_t$  é a volatilidade condicional estimada para o tempo  $t$ ,
- $\epsilon_t$  é o termo de erro,
- $\omega$  (intercepto) é um parâmetro positivo,
- $\alpha_1, \dots, \alpha_q$  são os coeficientes que capturam o efeito dos retornos passados na variância atual, todos sendo não-negativos para assegurar que  $h_t$  seja sempre positivo,
- $X_{t-1}^2, \dots, X_{t-q}^2$  representam os quadrados dos log-retornos passados.
- $q$  indica o número de lags (retornos passados) considerados no modelo.

Para estimar o modelo *ARCH*, é necessário seguir alguns passos. Primeiro, devemos garantir que os retornos financeiros sigam uma distribuição adequada, como a distribuição normal ou t-Student. As distribuições t-Student são frequentemente utilizadas em razão de suas caudas pesadas, o que permite capturar melhor os extremos observados nas séries financeiras.

A estimativa do modelo *ARCH* envolve a maximização da função de verossimilhança, onde se supõe que os termos de erro  $\epsilon_t$  seguem uma distribuição normal ou t-Student. É importante notar que, para que a estimação seja válida, é necessário que os termos de erro sejam independentes e identicamente distribuídos.

A independência dos termos de erro é uma restrição fundamental na modelagem *ARCH*. Violar essa independência pode resultar em estimativas viesadas ou inconsistentes dos parâmetros do modelo. Assim, é essencial testar a presença de autocorrelação nos resíduos do modelo, através da análise gráfica sugerida por (Morettin e Tolo, 2006) antes de proceder com a estimação.

Este modelo permite uma análise detalhada e realista da volatilidade, adaptando-se às mudanças do mercado e proporcionando uma base sólida para previsões e estratégias de investimento.

### 3.2 Modelo $GARCH(p, q)$

O modelo  $GARCH$  (*Generalized ARCH*), proposto por Tim Bollerslev em 1986 (Morettin e Tolo, 2006), é uma extensão do modelo  $ARCH$  que permite uma descrição mais eficiente e flexível da volatilidade. Esta generalização é particularmente útil em dados financeiros, onde a volatilidade exibe dependências de longo prazo, frequentemente observadas como agrupamentos de volatilidade.

O modelo é definido pelas seguintes equações:

$$X_t = \sqrt{h_t} \epsilon_t, \quad (3.3)$$

$$h_t = \omega + \sum_{i=1}^q \alpha_i X_{t-i}^2 + \sum_{j=1}^p \beta_j h_{t-j}, \quad (3.4)$$

onde:

- $X_t$  representa o log-retorno do ativo no tempo  $t$ ,
- $h_t$  é a volatilidade condicional estimada para o tempo  $t$ ,
- $\epsilon_t$  é o termo de erro,
- $\omega$  (intercepto) deve ser positivo,
- $\alpha_1, \dots, \alpha_q$  são coeficientes para os quadrados dos retornos passados,
- $\beta_1, \dots, \beta_p$  são coeficientes para as volatilidades condicionais passadas,
- $X_{t-1}^2, \dots, X_{t-q}^2$  e  $h_{t-1}, \dots, h_{t-p}$  refletem os retornos e volatilidades passados, respectivamente.

Conforme (Morettin e Tolo, 2006) destaca, a condição  $\sum_{i=1}^q (\alpha_i + \beta_i) < 1$ , onde  $q = \max(r, s)$ , é essencial para garantir a estacionariedade do modelo, assegurando que as flutuações de volatilidade diminuam ao longo do tempo.

Os parâmetros do modelo  $GARCH$  são estimados pelo método de máxima verossimilhança condicional, supondo a normalidade dos erros  $\epsilon_t$ . As estimativas são obtidas por métodos numéricos de maximização, conforme discutido em (Morettin e Tolo, 2006).

Este modelo é crucial para a compreensão e a previsão da volatilidade em séries temporais financeiras, fornecendo uma base robusta para decisões de investimento e gestão de riscos.

### 3.3 Teste Dickey-Fuller Aumentado (ADF)

A análise de séries temporais requer a verificação da estacionariedade, pois modelos como o *ARCH* e *GARCH* pressupõem que a média, a variância e a estrutura de autocorrelação da série sejam estáveis ao longo do tempo. Séries não estacionárias podem levar a resultados não confiáveis. Para avaliar essa propriedade, utilizamos o Teste ADF, proposto por (Dickey e Fuller, 1979), que verifica a presença de raiz unitária em séries temporais, testando a hipótese de não estacionariedade.

#### 3.3.1 Implementação no R

No presente trabalho, o teste Augmented Dickey-Fuller (ADF) foi implementado utilizando a função `adf.test` do pacote `tseries` no R. A especificação adotada segue o modelo padrão da função, que inclui um intercepto e uma tendência linear na equação de regressão, conforme descrito por (Banerjee, 1993). Essa escolha é justificada pela possibilidade de tendências determinísticas nos dados analisados, como é comum em séries financeiras ou econômicas. O número de defasagens ( $k$ ) foi determinado automaticamente pela regra

$$k = \text{trunc} \left( (n - 1)^{1/3} \right),$$

que fornece um limite superior adequado para o crescimento de  $k$  em função do tamanho da amostra. A hipótese alternativa considerada foi a estacionariedade, alinhada ao objetivo de verificar se as séries possuem raiz unitária.

#### 3.3.2 Formulação e Hipóteses

Considere uma série temporal  $X_t$ . O modelo de regressão auxiliar do ADF é:

$$\Delta X_t = \beta_1 + \beta_2 t + \delta X_{t-1} + \sum_{i=1}^k \alpha_i \Delta X_{t-i} + \epsilon_t, \quad (3.5)$$

onde:

- $X_t, X_{t-1}, X_{t-i}$  são os valores da série nos instantes  $t, t - 1, t - i$ ,
- $\beta_1$ : intercepto do modelo,
- $\beta_2$ : coeficiente de tendência temporal,

- $\delta$ : coeficiente que indica a presença de raiz unitária ( $\delta = 0$  implica não estacionariedade),
- $k$ : número de defasagens incluídas para controlar autocorrelação.

As hipóteses testadas são:

$$\begin{cases} H_0 : \delta = 0, & \text{a série é não-estacionária,} \\ H_1 : \delta < 0, & \text{a série é estacionária.} \end{cases}$$

A estatística do teste é calculada como:

$$T = \frac{\hat{\delta}}{se(\hat{\delta})},$$

onde  $\hat{\delta}$  é a estimativa de  $\delta$ .

### 3.3.3 Interpretação e Conclusão

Para concluir o teste, compara-se a estatística  $T$  com os valores críticos do ADF (tabelados ou fornecidos por softwares como R ([R Core Team, 2023](#))). Esses valores variam conforme o nível de significância (1%, 5%, 10%) e a especificação do modelo (com ou sem tendência). Se:

$$T < \text{Valor Crítico},$$

rejeitamos  $H_0$ , concluindo que a série é estacionária ( $\delta < 0$ ). Caso contrário, não há evidências para rejeitar a não estacionariedade. Na prática, a análise é automatizada por pacotes estatísticos, que também fornecem o  $p$ -valor associado à estatística  $T$ . Um  $p$ -valor abaixo do nível de significância adotado (0,05) reforça a rejeição de  $H_0$ , conforme discutido em ([Tsay, 2014](#)).

## 3.4 O Critério de Informação de Akaike (AIC)

O AIC, proposto por ([Akaike, 1974](#)), é um método de seleção de modelos que equilibra a qualidade do ajuste e a complexidade, é definido por:

$$\text{AIC} = -2 \ln \left( L(\hat{\theta} | \mathbf{x}) \right) + 2b, \quad (3.6)$$

- $L(\hat{\theta}|\mathbf{x}) = f(\mathbf{x}|\hat{\theta})$  é a função de verossimilhança,
- $\hat{\theta} = (\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_b)$  representam as estimativas de máxima verossimilhança dos parâmetros,
- $b$  é o número de parâmetros do modelo.

O termo  $-2\ln(L)$  reflete a aderência do modelo aos dados (quanto menor, melhor o ajuste), enquanto  $2b$  penaliza a complexidade, evitando superparametrização. A escolha entre modelos é feita pelo menor valor de AIC, priorizando modelos que explicam adequadamente a variável resposta sem excesso de parâmetros. Em contextos como modelos GARCH, essa penalização é crucial para evitar *overfitting* ao selecionar ordens  $p$  e  $q$  da volatilidade.

### 3.5 O Critério de Informação Bayesiano (BIC)

O BIC, desenvolvido por (Schwarz, 1978), surge de uma perspectiva bayesiana, aproximando o fator de Bayes para comparação de modelos. Sua formulação incorpora uma penalidade mais rigorosa para modelos complexos, especialmente em amostras grandes:

$$\text{BIC} = -2 \ln \left( L(\hat{\theta}|\mathbf{x}) \right) + \ln(n) \cdot b, \quad (3.7)$$

- $n$  é o número de observações,
- $L(\hat{\theta}|\mathbf{x}) = f(\mathbf{x}|\hat{\theta})$  é a função de verossimilhança,
- $\hat{\theta} = (\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_b)$  representam as estimativas de máxima verossimilhança dos parâmetros,
- $b$  é o número de parâmetros do modelo.

A penalidade  $\ln(n) \cdot b$  cresce com o tamanho da amostra, tornando o BIC mais conservador que o AIC. Assim como o AIC, modelos com menor BIC são preferíveis, mas o BIC tende a selecionar estruturas mais simples em cenários com muitos dados. Para séries financeiras modeladas por GARCH, essa característica é valiosa, pois auxilia na identificação de parâmetros  $p$  e  $q$  que capturam a volatilidade sem comprometer a generalização.

### 3.6 Teste de Ljung-Box

O teste de Ljung-Box verifica a presença de autocorrelação nos resíduos de um modelo de séries temporais. As hipóteses são:

$$\begin{cases} H_0 : \text{os resíduos não possuem autocorrelação,} \\ H_1 : \text{os resíduos possuem autocorrelação.} \end{cases}$$

A estatística do teste é dada por:

$$Q(k) = n(n+2) \sum_{j=1}^K \frac{\hat{\rho}_j^2}{n-j},$$

onde:

- $\hat{\rho}_j^2$ : autocorrelação estimada na defasagem  $j$ ,
- $n$ : tamanho da amostra,
- $K$ : número de defasagens testadas.

Sob  $H_0$ ,  $Q(k)$  segue uma distribuição  $\chi^2$  com  $K - p - q$  graus de liberdade ( $p$  e  $q$  são as ordens do modelo).

Na prática, implementa-se o teste via softwares como R (R Core Team, 2023). Exemplificando, um  $p$ -valor maior que o nível de significância (0,05) indica falha em rejeitar  $H_0$ , sugerindo que os resíduos são independentes (Tsay, 2014).

### 3.7 Magazine Luiza (MGLU3.SA)

Fundada na década de 1950 em Franca, Magazine Luiza inicialmente se concentrou na venda de eletrodomésticos. Desde sua fundação, a Magazine Luiza se destacou no varejo brasileiro, enfrentando desafios e aproveitando oportunidades para crescer. Em 2011, a empresa decidiu abrir seu capital, buscando fortalecer sua posição no mercado e sustentar seu crescimento. Em 2019, a empresa, agora conhecida como Magalu<sup>1</sup>, reformulou sua identidade para uma plataforma digital de varejo. Atualmente, opera 1.303 lojas físicas em 20 estados do Brasil, refletindo sua expansiva presença no mercado nacional.

<sup>1</sup><https://ri.magazineluiza.com.br/show.aspx?idCanal=urUqu4hANldyCLgMRgOsTw==>

A abertura de capital permitiu à Magalu captar recursos para financiar sua expansão e modernização, com investimentos em novas lojas, infraestrutura, tecnologia e inovação. Isso foi essencial para competir em um mercado dinâmico e competitivo. Além disso, a presença no mercado de ações fortaleceu a marca da empresa, aumentando sua visibilidade e credibilidade entre investidores, clientes e parceiros comerciais.

Outro motivo relevante foi a possibilidade de proporcionar liquidez aos acionistas, permitindo a negociação de ações na bolsa e atraindo novos investidores. Os recursos obtidos também permitiram à Magalu reduzir seu endividamento, melhorando sua saúde financeira e fortalecendo a capacidade de enfrentar desafios futuros.

Os impactos da abertura de capital foram positivos, proporcionando uma base de capital mais robusta, promovendo uma gestão mais eficiente e melhorando a percepção dos investidores e do público sobre a empresa. Em resumo, a decisão de abrir seu capital foi estratégica para assegurar o crescimento, fortalecer a marca, proporcionar liquidez aos acionistas e melhorar a saúde financeira da Magazine Luiza, posicionando-a de maneira sólida e competitiva no varejo nacional.

A análise subsequente utiliza dados descritivos processados no *R* (R Core Team, 2023) para examinar as variações nos valores de fechamento das ações da Magalu, comparando três períodos distintos: o total, antes e após a aquisição da Kabum.

Tabela 3.1: Estatísticas Descritivas dos preços de fechamento da Magalu

<b>Estatísticas</b>	<b>Total</b>	<b>Antes</b>	<b>Depois</b>
<b>Mínimo</b>	0.028	0.028	1.244
<b>Mediana</b>	1.712	0.369	3.470
<b>Média</b>	4.257	4.033	5.095
<b>Máximo</b>	25.674	25.674	22.354
<b>Desvio Padrão</b>	6.246	6.610	4.541
<b>Variância</b>	39.017	43.703	20.627

A Tabela 3.1 compara as três séries temporais analisadas. Observamos que a mediana aumentou significativamente após a aquisição da Kabum, de 0.369 para 3.470. Esta elevação reflete a mudança de dinâmica no valor das ações após o evento. Durante o período de 2012 a 2017, a série manteve valores baixos, o que influenciou consideravelmente a mediana do período anterior à aquisição. Ainda que o valor máximo tenha ocorrido antes da aquisição, a média pós-aquisição sugere um aumento geral nos preços das ações. Finalmente, a redução no desvio padrão e na variância indica uma menor dispersão dos valores em torno da média, sugerindo uma estabilização da volatilidade das ações após a aquisição da Kabum.

A Figura 3.1 mostra o comportamento dos preços de fechamento das ações da Magalu de 2011 a 2023. Os dados, extraídos do Yahoo Finanças<sup>2</sup>, foram analisados utilizando o software *R*, conforme documentado no Apêndice A.

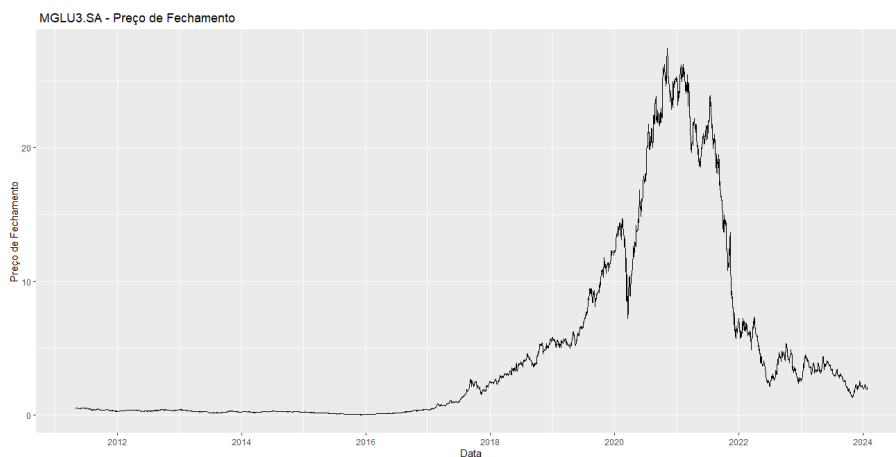


Figura 3.1: Preço de fechamento Magalu.

Após analisar o comportamento da série temporal, observamos uma tendência crescente de 2018 até 2021 e uma tendência decrescente de 2021 a 2022, sem padrões de sazonalidade aparentes. Para confirmar a natureza não estacionária da série, realizamos o teste Dickey-Fuller (Dickey e Fuller, 1979) no *R*. Esse teste é empregado para verificar a presença de uma raiz unitária, indicativa de tendências ou mudanças ao longo do tempo, caracterizando a não estacionariedade. A hipótese nula do teste Dickey-Fuller é que a série possui uma raiz unitária, ou seja, é não estacionária. O teste resultou em um  $p$  – valor de 0.9644. Como o  $p$  – valor é maior que 0.05, não rejeitamos a hipótese nula, confirmando a presença de não estacionariedade sugerida pela análise visual. Se o  $p$  – valor fosse menor que 0.05, rejeitaríamos a hipótese nula, sugerindo que a série

<sup>2</sup><https://finance.yahoo.com/quote/MGLU3.SA/key-statistics?p=MGLU3.SA>

poderia ser considerada estacionária.

Devido à natureza da série financeira, optamos por transformar os dados utilizando o logaritmo para estabilizar a variância e facilitar a modelagem. Adicionalmente, a tendência foi removida calculando as diferenças entre observações consecutivas com a função *diff* no *R* (R Core Team, 2023).

A Figura 3.2 mostra os preços de fechamento das ações da Magalu após as transformações aplicadas.




Figura 3.2: Log retorno do preço de fechamento Magalu.

Após as transformações, um novo teste Dickey-Fuller (Dickey e Fuller, 1979) foi realizado, apresentando um *p* – *valor* de aproximadamente 0,01. Este resultado indica que a série transformada é estacionária, permitindo a continuação da análise com base nos log-retornos.

### 3.7.1 Magazine Luiza antes da compra da Kabum




Figura 3.3: Preço de fechamento Magalu antes da compra.

A análise do comportamento dos preços de fechamento das ações da Magalu antes da aquisição da Kabum revela uma tendência crescente entre 2017 e 2021, sem indícios claros de sazonalidade. Para testar a estacionariedade da série, utilizamos o teste Dickey-Fuller no  $R$ . O  $p$  – valor obtido foi de 0.9789, indicando, conforme visualizado no gráfico, que a série é não estacionária.

Para aprofundar a análise, aplicamos duas transformações à série: inicialmente, o logaritmo para estabilizar a variância, seguido da diferenciação para remover a tendência. Essas transformações foram realizadas utilizando as funções  $\log$  e  $\text{diff}$  no  $R$ .

Após essas alterações, um novo teste Dickey-Fuller (Dickey e Fuller, 1979) produziu um  $p$  – valor de aproximadamente 0.01, confirmando que a série transformada agora é estacionária, o que permite prosseguir com a análise do log-retorno.




Figura 3.4: Log retorno do preço de fechamento Magalu antes da compra.

Seguindo a recomendação de [Morettin e Tolo, 2006](#), analisamos três gráficos:

- Função de Autocorrelação.
- Função de Autocorrelação Parcial.
- Função de Autocorrelação do log-retornos ao quadrado.




Figura 3.5: Função de Autocorrelação para o log-retorno antes da compra.




Figura 3.6: Função de Autocorrelação Parcial para o log-retorno antes da compra.




Figura 3.7: Função de Autocorrelação do quadrado do log-retorno para antes da compra.

Os gráficos de autocorrelação Figura(3.5) e autocorrelação parcial Figura(3.6) não mostram padrões significativos, sugerindo a ausência de autocorrelações. No entanto, a função de autocorrelação do quadrado dos retornos Figura(3.7) indica volatilidade. Especificamente, a presença de barras que excedem os limites de confiança (as linhas tracejadas azuis no gráfico) em lags significativos sugere que os retornos ao quadrado são autocorrelacionados. Sugerindo que modelos como *ARCH* ou *GARCH* podem ser

adequados para modelar a série, dada a presença de agrupamentos de volatilidade.

### 3.7.2 Magazine Luiza após a compra da Kabum




Figura 3.8: Preço de fechamento Magalu após a compra.

A série temporal dos preços de fechamento das ações da Magalu após a compra da Kabum mostra uma tendência decrescente de 2021 até 2023, sem sinais evidentes de sazonalidade. Para avaliar a estacionariedade da série, aplicamos o teste Dickey-Fuller (Dickey e Fuller, 1979) no R (R Core Team, 2023), que resultou em um  $p$  – valor de aproximadamente 0,01, indicando estacionariedade.

No entanto, uma observação visual do gráfico revela uma clara tendência decrescente, o que contraria a sugestão de estacionariedade pelo teste. Essa divergência pode ser explicada pela influência de outros fatores estruturais ou por características da série que não são capturadas pelo teste. Outro possível motivo para essa discrepância é o menor número de observações disponíveis (o período anterior era de 11 anos, e o atual de 4 anos), que pode afetar a robustez dos resultados do teste.

Por isso, optamos por transformar a série utilizando o log-retorno para estabilizar a variância, facilitando assim a análise.

Então, assim como feito acima, utilizaremos o log-retorno para continuar com a análise dos três gráficos.




Figura 3.9: Função de Autocorrelação para o log-retorno depois da compra.

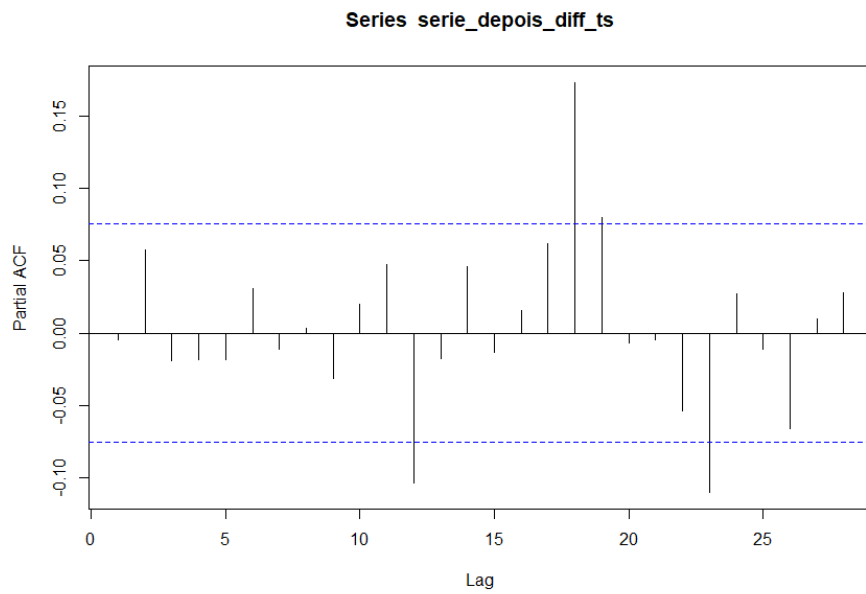


Figura 3.10: Função de Autocorrelação Parcial para o log-retorno depois da compra.

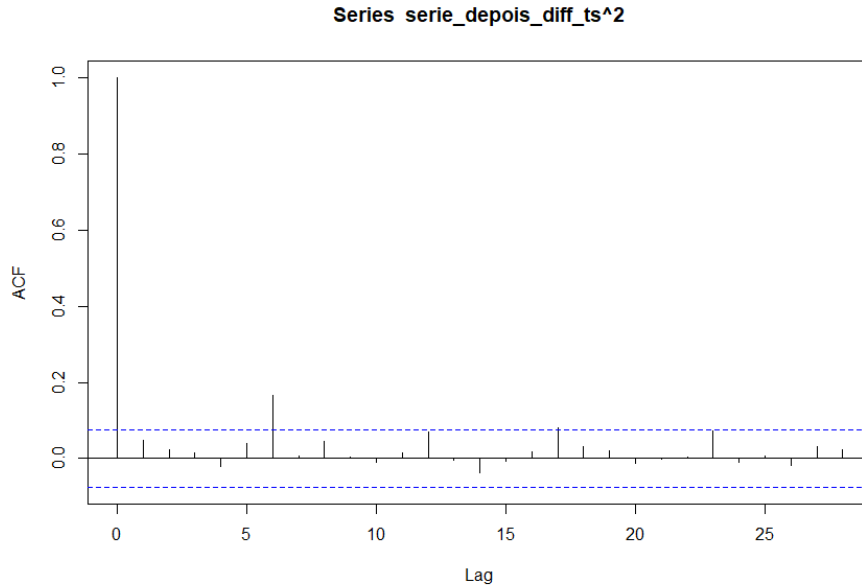


Figura 3.11: Função de Autocorrelação do quadrado do log-retorno para depois da compra.

Os gráficos de autocorrelação Figura(3.9), Figura(3.10) autocorrelação parcial e Figura(3.11) autocorrelação dos retornos ao quadrado, após a transformação dos dados, não mostram autocorrelações significativas. Essa ausência de autocorrelações sugere que modelos baseados apenas em autocorrelações passadas, como os modelos *ARCH* ou *GARCH*, podem não ser os mais adequados para modelar a série no período após a aquisição.

Essa observação é crucial para nossa análise, pois indica uma mudança significativa na dinâmica dos dados. Antes da aquisição da Kabum, a série demonstrava características que se alinhavam bem com um modelo *GARCH*, evidenciado pela presença de autocorrelações dos retornos ao quadrado, que sugeriam volatilidade agrupada. No entanto, após a aquisição, esses padrões não se mantêm, indicando que o modelo *GARCH* pode não capturar adequadamente a nova dinâmica do mercado.

### 3.8 Modelagem *GARCH* para Antes da Compra

Neste capítulo, apresentamos a aplicação de diferentes modelos *GARCH* para analisar a série de retornos financeiros antes da aquisição da Kabum. A escolha dos modelos *GARCH*(1,1), *GARCH*(1,2), *GARCH*(2,1) e *GARCH*(2,2) baseia-se na necessidade de capturar possíveis dinâmicas de volatilidade da série, considerando diferentes ordens de dependência entre choques passados e persistência da variância condicional. Modelos com ordens maiores podem teoricamente capturar estruturas mais complexas, mas também aumentam a quantidade de parâmetros estimados, o que pode levar a um ajuste excessivo aos dados.

Dessa forma, os modelos são comparados utilizando os Critérios de Informação de Akaike (AIC) e Bayesiano (BIC), que auxiliam na escolha de uma parametrização adequada equilibrando ajuste e complexidade.

Tabela 3.2: Comparação dos Critérios AIC e BIC para os modelos antes da compra

<b>Modelo</b>	<b>AIC</b>	<b>BIC</b>
<i>GARCH</i> (1, 1)	-4,0095	-4,0003
<i>GARCH</i> (1, 2)	-4,0095	-4,0003
<i>GARCH</i> (2, 1)	-4,0085	-3,9969
<i>GARCH</i> (2, 2)	-4,0106	-3,9968

Os valores obtidos para AIC e BIC são bastante próximos entre os modelos testados, sugerindo que todos proporcionam ajustes semelhantes aos dados. No entanto, a escolha do modelo mais apropriado deve levar em conta não apenas a qualidade do ajuste, mas também a parcimônia, isto é, a minimização do número de parâmetros sem perda significativa de informação.

Embora o modelo *GARCH*(2,2) apresente o menor valor de AIC, a diferença em relação ao modelo *GARCH*(1,1) é pequena. Como o *GARCH*(1,1) possui menos parâmetros e ainda assim apresenta valores de AIC e BIC próximos aos dos modelos mais complexos, ele é escolhido como a melhor opção para modelar a volatilidade da série antes da aquisição da Kabum. Essa decisão prioriza um equilíbrio entre simplicidade e capacidade de representar a estrutura dos dados.

### 3.8.1 Especificação do Modelo $GARCH(1, 1)$ para antes da compra

O modelo  $GARCH(1, 1)$  ajustado à série de retornos é definido pelas equações:

$$X_t = \sqrt{h_t}\epsilon_t, \quad (3.8)$$

$$h_t = \omega + \alpha_1 X_{t-1}^2 + \beta_1 h_{t-1}, \quad (3.9)$$

onde:

- $X_t$ : log-retorno do ativo no tempo  $t$ ,
- $h_t$ : volatilidade condicional no tempo  $t$ ,
- $\epsilon_t$  é o termo de erro,
- $\omega$ : intercepto,
- $\alpha_1$ : impacto dos choques passados ( $X_{t-1}^2$ ) na variância atual,
- $\beta_1$ : persistência da variância condicional anterior.

#### Parâmetros Estimados e Significância

Os parâmetros estimados pelo software R (([R Core Team, 2023](#))) são:

- $\omega = 0,0001$ :
  - $p$ -valor (estimativa padrão): 0,0002 ( $< 0,05$ , significativo),
  - $p$ -valor (erro robusto): 0,2292 ( $> 0,05$ , não significativo).
- $\alpha_1 = 0,1308$ :
  - $p$ -valor (estimativa padrão):  $< 0,0001$ ,
  - $p$ -valor (erro robusto): 0,0404,
  - Ambos significativos a  $\alpha = 5\%$ .
- $\beta_1 = 0,7857$ :
  - $p$ -valor (estimativa padrão):  $< 0,0001$ ,

- $p$ -valor (erro robusto):  $< 0,0001$ ,
- Ambos significativos a  $\alpha = 5\%$ .

### Equação Final e Interpretação

A equação estimada para a volatilidade condicional do modelo GARCH(1,1) para antes da compra é dada por:

$$h_t = 0,0001 + 0,1308 \cdot X_{t-1}^2 + 0,7857 \cdot h_{t-1}.$$

Para um nível de significância de  $\alpha = 5\%$ , os coeficientes  $\alpha_1 = 0,1308$  e  $\beta_1 = 0,7857$  apresentaram significância estatística tanto na estimativa padrão quanto na robusta, indicando que tanto os choques passados ( $X_{t-1}^2$ ) quanto a persistência da volatilidade ( $h_{t-1}$ ) influenciam significativamente a variância condicional.

Por outro lado, o intercepto  $\omega = 0,0001$ , embora significativo na estimativa padrão ( $p$ -valor = 0,0001), não se mostrou estatisticamente relevante ao considerarmos o erro robusto ( $p$ -valor = 0,2292). Em séries financeiras, é comum a presença de heterocedasticidade nos resíduos, o que pode levar à subestimação ou superestimação dos erros padrão na abordagem convencional. Assim, os erros robustos são preferidos, pois corrigem essa possível inconsistência, tornando as inferências mais confiáveis (Tsay, 2014).

Dessa forma, a interpretação dos parâmetros deve considerar a estimativa robusta, o que sugere que a volatilidade condicional da série é majoritariamente explicada pelos efeitos dos retornos passados e pela persistência da variância, enquanto o termo de intercepto pode não desempenhar um papel relevante na dinâmica do modelo.

### 3.8.2 Adequação do Modelo $GARCH(1, 1)$ para o período antes da compra

Analisaremos a adequação do modelo  $GARCH(1, 1)$  ajustado para a série temporal dos preços de fechamento das ações da Magalu antes da compra da Kabum. A análise de resíduos nos permitirá verificar se o modelo captura corretamente a dinâmica de volatilidade e se os resíduos resultantes atendem às suposições de um bom ajuste, sem apresentar autocorrelações significativas.




Figura 3.12: Função de Autocorrelação para os resíduos do Modelo  $GARCH(1,1)$  no período anterior a compra.




Figura 3.13: Função de Autocorrelação Parcial para os resíduos do Modelo  $GARCH(1,1)$  no período anterior a compra.




Figura 3.14: Função de Autocorrelação dos resíduos ao Quadrado para o Modelo  $GARCH(1,1)$  no período anterior a compra.

A análise de resíduos do modelo ajustado para a série da Magalu antes da compra da Kabum sugere que o modelo  $GARCH(1,1)$  captura a dinâmica de volatilidade de maneira eficaz, sem deixar autocorrelações significativas nos resíduos ajustados. Isso é confirmado pelos testes de Ljung-Box (Tsay, 2014) observados na Tabela(3.3), onde a maioria dos p-valores não indica autocorrelação significativa, e pelos gráficos Figura(3.12) e Figura(3.13), a maior parte das autocorrelações está dentro dos limites de confiança.

Tabela 3.3: P-valor do Teste de Ljung-Box para antes da compra

Lag (k)	p-valor
1	0,0429
2	0,1009
3	0,2033
4	0,2954
5	0,0543
6	0,0900
10	0,0931
15	0,0433
20	0,0737

Além disso, a análise da Figura(3.14) dos resíduos padronizados indica que a volatilidade é bem capturada pelo modelo, uma vez que não há autocorrelações significativas na série de resíduos ao quadrado. Portanto, o modelo  $GARCH(1,1)$  é adequado para modelar a volatilidade da série temporal em questão, capturando a estrutura de dependência condicional da variância.

### 3.9 Modelagem *GARCH* para Depois da Compra

Neste capítulo, apresentamos a aplicação de diferentes modelos ARCH e GARCH para analisar a série de retornos financeiros após a aquisição da Kabum pela Magalu. A escolha dos modelos testados baseia-se em dois critérios principais: a identificação de um lag significativo na autocorrelação dos retornos ao quadrado e a necessidade de avaliar a persistência da volatilidade condicional ao longo do tempo.

Inicialmente, a inclusão do modelo ARCH(6) foi motivada pela observação da função de autocorrelação dos quadrados dos log-retornos (*acfd2*), que indicou um comportamento significativo no lag 6. Isso sugere que choques de volatilidade podem exibir dependência temporal com essa defasagem, justificando sua consideração na modelagem.

Além disso, testamos os modelos GARCH(1,1), GARCH(1,2), GARCH(2,1) e GARCH(2,2), seguindo a mesma lógica aplicada ao período anterior. A escolha dessas parametrizações permite avaliar a relação entre choques passados e a persistência da volatilidade condicional, possibilitando a comparação entre estruturas mais simples e mais flexíveis.

Os modelos foram comparados utilizando os Critérios de Informação de Akaike (AIC) e Bayesiano (BIC), que auxiliam na escolha de uma especificação que balanceie ajuste e parcimônia.

Tabela 3.4: Comparação dos Critérios AIC e BIC para os modelos depois da compra

<b>Modelo</b>	<b>AIC</b>	<b>BIC</b>
<i>ARCH</i> (6)	-3.252	-3.199
<i>GARCH</i> (1, 1)	-3.255	-3.228
<i>GARCH</i> (1, 2)	-3.251	-3.218
<i>GARCH</i> (2, 1)	-3.252	-3.219
<i>GARCH</i> (2, 2)	-3.249	-3.209

Os valores obtidos para AIC e BIC são relativamente próximos entre os modelos testados, sugerindo que todos proporcionam ajustes semelhantes aos dados. Entretanto, um fator relevante a ser considerado é a ausência de autocorrelação significativa nos resíduos ao quadrado, o que pode indicar que os modelos *ARCH* e *GARCH* não sejam os mais adequados para capturar a dinâmica da volatilidade nesse período.

Apesar dessa limitação, optamos por selecionar o modelo que melhor se ajusta aos dados disponíveis dentro das classes testadas. Considerando os critérios AIC e BIC, escolhemos o modelo GARCH(1,1) para dar continuidade à análise, equilibrando parcimônia e adequação ao período analisado.

### 3.9.1 Especificação do Modelo $GARCH(1, 1)$ para o período pós-compra

Neste capítulo, apresentamos a aplicação do modelo  $GARCH(1, 1)$  para analisar a série de retornos financeiros após a aquisição da Kabum pela Magalu. Diferentemente do período anterior, os dados não apresentam autocorrelação do quadrado dos retornos, o que pode comprometer a adequação do modelo. Assim, realizamos a estimação dos parâmetros e avaliamos sua significância estatística, verificando a adequação do modelo por meio da análise de resíduos e testes estatísticos.

#### Parâmetros Estimados e Significância

Os parâmetros estimados pelo software R (([R Core Team, 2023](#))) para o período pós-aquisição são:

- $\omega = 0,0001$ :
  - $p$ -valor (estimativa padrão): 0,0001 ( $< 0,05$ , significativo),
  - $p$ -valor (erro robusto): 0,1987 ( $> 0,05$ , não significativo).
- $\alpha_1 = 0,0613$ :
  - $p$ -valor (estimativa padrão): 0,0121,
  - $p$ -valor (erro robusto): 0,0359,
  - Significativo com  $\alpha = 5\%$  em ambas as estimativas.
- $\beta_1 = 0,8948$ :
  - $p$ -valor (estimativa padrão):  $< 0,0001$ ,
  - $p$ -valor (erro robusto):  $< 0,0001$ ,
  - Significativo com  $\alpha = 5\%$  em ambas as estimativas.

#### Equação Final e Interpretação

A equação estimada para a volatilidade condicional do modelo  $GARCH(1, 1)$  após a compra é dada por:

$$h_t = 0,0001 + 0,0613 \cdot X_{t-1}^2 + 0,8948 \cdot h_{t-1}.$$

Para  $\alpha = 5\%$ , os coeficientes  $\alpha_1 = 0,0613$  e  $\beta_1 = 0,8948$  apresentaram significância estatística tanto na estimativa padrão quanto na robusta, indicando que choques passados ( $X_{t-1}^2$ ) e a persistência da volatilidade ( $h_{t-1}$ ) continuam influenciando a variância condicional.

Entretanto, o intercepto  $\omega = 0,0001$ , embora significativo na estimativa padrão ( $p$ -valor = 0,00015), não se mostrou estatisticamente relevante ao considerarmos a estimativa robusta ( $p$ -valor = 0,1987). Como dito anteriormente, a priorização de erros robustos é recomendada para maior confiabilidade, especialmente em séries com heterocedasticidade (Tsay, 2014).

### 3.9.2 Adequação do Modelo $GARCH(1, 1)$ para o período depois da compra

Analisaremos a adequação do modelo  $GARCH(1, 1)$  ajustado para a série temporal dos preços de fechamento das ações da Magalu após a compra da Kabum. A análise de resíduos nos permitirá verificar se o modelo captura corretamente a dinâmica de volatilidade e se os resíduos resultantes atendem às suposições de um bom ajuste, sem apresentar autocorrelações significativas.

#### Testes de Autocorrelação para após a compra

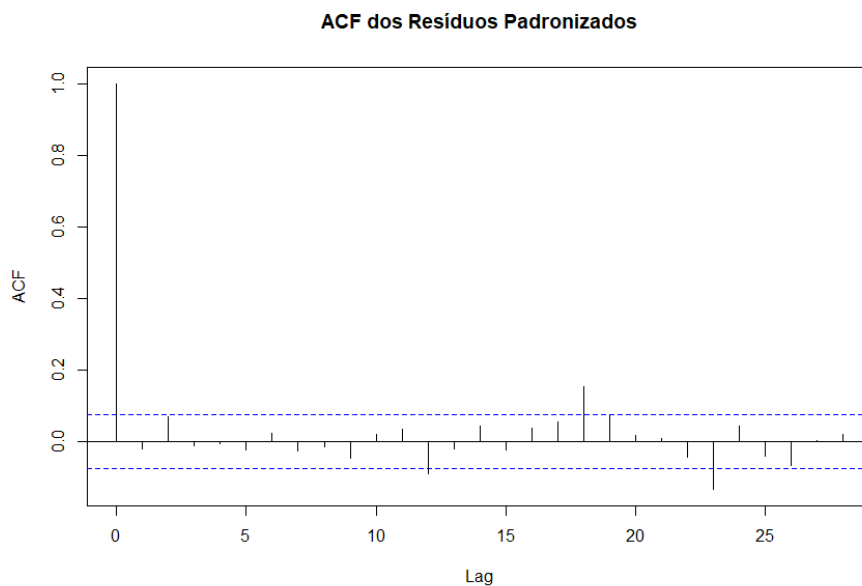


Figura 3.15: Função de Autocorrelação para para os resíduos do Modelo  $GARCH(1,1)$  no período posterior a compra.

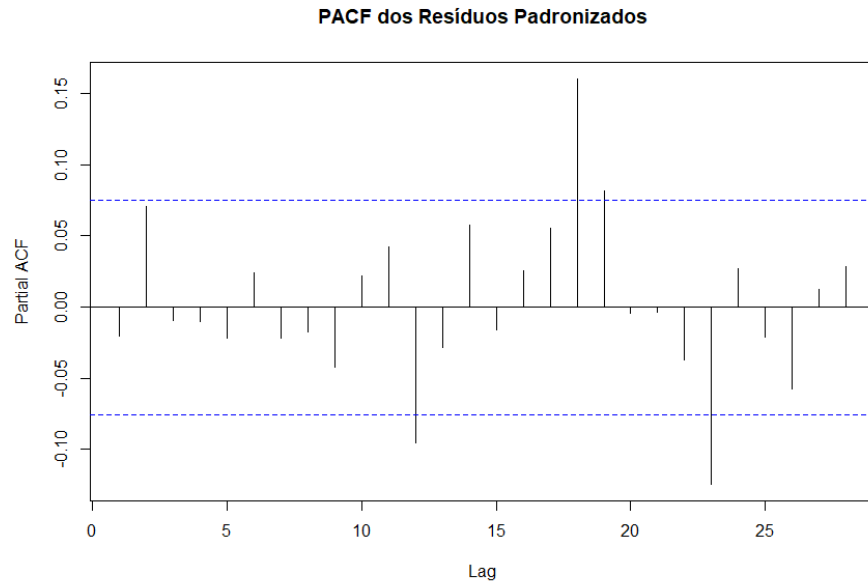


Figura 3.16: Função de Autocorrelação Parcial para para os resíduos do Modelo GARCH(1,1) no período posterior a compra.




Figura 3.17: Função de Autocorrelação dos resíduos ao Quadrado para o Modelo GARCH(1,1) no período posterior a compra.

Aplicamos o teste de Ljung-Box aos resíduos padronizados do modelo ajustado para verificar a presença de autocorrelação serial. Os resultados são apresentados na Tabela 3.5

Tabela 3.5: P-valor do Teste de Ljung-Box para após a compra

Lag (k)	p-valor
1	0,6025
2	0,1577
3	0,2851
4	0,4335
5	0,5282
6	0,6043
10	0,7442
15	0,4423
20	0,006417

A análise dos resíduos do modelo ajustado para a série da Magalu após a compra da Kabum sugere que o modelo  $GARCH(1,1)$  não captura completamente a dinâmica da volatilidade, uma vez que algumas autocorrelações significativas ainda persistem nos resíduos. Embora os testes de Ljung-Box (Tsay, 2014) apresentados na Tabela 3.5 indiquem que a maioria dos  $p$ -valores não sugere autocorrelação significativa até a defasagem 15, observamos que no lag 20 o  $p$ -valor é menor que 0,05, indicando autocorrelação significativa em defasagens mais altas.

Além disso, as funções de autocorrelação e autocorrelação parcial dos resíduos padronizados, mostradas nas Figuras 3.15 e 3.16, evidenciam que algumas autocorrelações

ultrapassam os limites de confiança, sugerindo que o modelo não conseguiu capturar adequadamente todas as dependências temporais presentes nos dados após a aquisição. Isso indica que a volatilidade não foi completamente modelada, deixando efeitos residuais não explicados.

### 3.9.3 Análise Comparativa

Ao comparar os resultados do modelo  $GARCH(1,1)$  nos períodos antes e depois da aquisição da Kabum, observamos diferenças significativas na adequação do modelo à dinâmica da volatilidade.

No período anterior à compra, o modelo  $GARCH(1,1)$  demonstrou boa aderência aos dados. A análise dos resíduos indicou ausência de autocorrelação significativa, e os gráficos das funções de autocorrelação e autocorrelação parcial mostraram que os valores estavam dentro dos limites de confiança, conforme ilustrado nas Figuras 3.12 e 3.13. Além disso, os testes de Ljung-Box (Tabela 3.3) reforçaram essa adequação, sugerindo que o modelo capturou corretamente a volatilidade condicional antes da aquisição.

Já no período posterior à compra, a adequação do modelo  $GARCH(1,1)$  foi comprometida. Os resíduos padronizados apresentaram evidências de autocorrelação significativa em defasagens mais altas, conforme mostrado nas Figuras 3.15 e 3.16, e no teste de Ljung-Box (Tabela 3.5), onde observamos um  $p$ -valor inferior a 0,05 para o lag 20. Esse resultado sugere que o modelo não conseguiu capturar completamente a estrutura da volatilidade após a aquisição.

As discrepâncias entre os períodos indicam a possibilidade de mudanças estruturais no comportamento dos retornos após a compra da Kabum, tornando a dinâmica da volatilidade distinta. Enquanto no período anterior, a volatilidade condicional era bem descrita pelo modelo, no período posterior, há indícios de que outras fontes de variabilidade podem estar influenciando os retornos. Possíveis explicações incluem alterações no mercado, mudanças na percepção dos investidores ou eventos externos que impactaram a volatilidade de forma não capturada pelo modelo  $GARCH(1,1)$ .

Dessa forma, os resultados sugerem que a estrutura da volatilidade se tornou mais complexa após a aquisição, e que o modelo utilizado pode não ser suficiente para descrever completamente essa nova dinâmica. Isso reforça a importância de explorar extensões do modelo, ou abordagens mais flexíveis, para avaliar melhor a volatilidade nesse novo cenário.



# Capítulo 4

## Conclusão

Este estudo teve como objetivo analisar as variações na volatilidade das ações da Magazine Luiza em relação aos preços de fechamento antes e após a aquisição da Kabum. Para isso, aplicamos métodos estatísticos e modelagem de séries temporais, utilizando modelos *GARCH*, conforme descrito por (Morettin e Tolo, 2006) e (Tsay, 2014), a fim de capturar a dinâmica da volatilidade da série e examinar possíveis mudanças no comportamento dos retornos.

A análise da série de preços de fechamento antes da compra da Kabum revelou uma tendência crescente de 2017 a 2021, sem indícios evidentes de sazonalidade. A transformação da série por meio do cálculo do log-retorno e da diferenciação permitiu estabilizar a variância, tornando-a estacionária e adequada para modelagem. Os gráficos de autocorrelação e os testes de Ljung-Box indicaram que o modelo *GARCH*(1, 1) foi capaz de representar a volatilidade condicional, sugerindo que essa abordagem foi apropriada para esse período.

No entanto, no período posterior à aquisição da Kabum, de 2021 a 2023, os resultados indicaram um comportamento distinto. Foi observada uma tendência decrescente nos preços das ações, e, apesar da confirmação de estacionariedade pelo teste Dickey-Fuller, optamos por seguir analisando os retornos. Para esse período, os gráficos de autocorrelação e o teste de Ljung-Box mostraram que o modelo *GARCH*(1, 1) não capturou completamente a estrutura da volatilidade. A presença de autocorrelações significativas em defasagens mais altas sugere que a dinâmica da volatilidade pode ter mudado nesse período, tornando o modelo menos adequado.

O declínio nos preços das ações da Magazine Luiza após a aquisição da Kabum pode estar relacionado a diversos fatores não considerados neste estudo, como mudanças no mer-

cado, oscilações macroeconômicas ou expectativas dos investidores. A aquisição pode ter alterado a percepção dos agentes do mercado, o que poderia ter impactado a volatilidade dos retornos. No entanto, os modelos analisados não permitem afirmar conclusivamente a relação entre a aquisição e a dinâmica dos preços.

A análise sugere que o comportamento dos retornos da Magalu reflete características distintas nos dois períodos observados. Antes da aquisição, o modelo *GARCH*(1,1) mostrou-se adequado para capturar a volatilidade, enquanto após a aquisição, os resultados indicam que a estrutura da volatilidade pode ter se tornado mais complexa. Isso sugere a necessidade de explorar abordagens alternativas para modelar a volatilidade no período pós-aquisição.

Dessa forma, futuras pesquisas podem investigar modelos mais flexíveis, como variações do *GARCH* que incluam componentes adicionais ou considerem mudanças estruturais no mercado. Além disso, a inclusão de variáveis exógenas pode ser útil para avaliar a influência de fatores econômicos e setoriais na volatilidade das ações da Magazine Luiza. Essas abordagens poderiam fornecer uma compreensão mais abrangente das dinâmicas do mercado e contribuir para análises mais robustas no contexto de grandes aquisições corporativas.

Adicionalmente, recentes mudanças estratégicas na empresa, como a obtenção da licença do Banco Central para operar a MagaluPay<sup>1</sup>, podem ter impacto significativo na percepção dos investidores e no comportamento da volatilidade das ações. Estudos futuros podem investigar os efeitos dessa nova estrutura financeira na dinâmica dos preços da companhia.

---

<sup>1</sup>Acessado em 21/02/25: <https://economia.uol.com.br/colunas/graciliano-rocha/2025/02/22/como-a-nova-plataforma-financeira-vai-mudar-o-negocio-do-magalu.htm?cmpid=copiaecola>

# Referências Bibliográficas

- Akaike, H. (1974). Stochastic theory of minimal realization. *IEEE Transactions on Automatic Control*, **19**(6), 667–674.
- Banerjee, A. (1993). *Co-integration, Error Correction, and the Econometric Analysis of Non-stationary Data*. Advanced texts in econometrics. Oxford University Press. ISBN 9780198288107.
- Dickey, D. A. e Fuller, W. A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American statistical association*, **74**(366a), 427–431.
- Morettin, P. e Tolo, C. (2006). Análise de séries temporais—2<sup>a</sup> edição revista e ampliada. *ABE-Projeto Fisher*, Editora Edgar Blücher.
- R Core Team (2023). *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria.
- Schwarz, G. (1978). Estimating the dimension of a model. *The annals of statistics*, páginas 461–464.
- Tsay, R. S. (2014). *An introduction to analysis of financial data with R*. John Wiley & Sons.



# Apêndice A

## Códigos

Listing A.1: Código R para análise de séries temporais da Magalu

```
1
2 library(ggplot2)
3 library(tidyr)
4 library(quantmod)
5 library(forecast)
6 library(tseries)
7 library(lmtest)
8 library(xts)
9 library(seasonal)
10 library(zoo)
11 library(dplyr)
12 library(rugarch)
13 library(fGarch)
14 library(tidyverse)
15 library(moments)
16
17 dados= MGLU3.SA
18 dados = na.omit(dados) # remover as linhas com NA's
19 dados$Date <- as.Date(dados$Date)
20
21 #GGPLOT DA Srie
22
23
24 ggplot(dados, aes(x = Date, y = Close)) +
25   geom_line() +
26   labs(title = "MGLU3.SA - Preço de Fechamento",
```

```
27     x = "Data",
28     y = "Pre o de Fechamento")+
29     scale_x_date(date_labels = "%Y", date_breaks = "2_year")
30
31
32
33 # Agora, vamos criar a s rie temporal
34 serie_temporal <- zoo(dados$Close, order.by = as.Date(dados$Date, format
35     = "%Y-%m-%d"))
36
37 adf.test(serie_temporal)
38
39 # Aplicando o log na s rie
40 serie_temporal_log <- log(serie_temporal)
41
42 plot(serie_temporal_log)
43
44 # Aplicando diff na s rie
45 log_diff_serie <- diff(serie_temporal_log)
46
47 plot(log_diff_serie)
48
49 class(log_diff_serie)
50
51 # Convertendo o objeto 'zoo' para 'ts'
52 log_diff_serie_ts <- ts(coredata(log_diff_serie), start = start(log_diff
53     _serie), frequency = frequency(log_diff_serie))
54
55 plot(log_diff_serie_ts)
56 acf(log_diff_serie_ts)
57 pacf(log_diff_serie_ts)
58 acf(log_diff_serie_ts^2)
59
60 #Separar antes e depois
61
62 antes <- window(serie_temporal, end = as.Date("2021-07-13"))
63 depois <- window(serie_temporal, start = as.Date("2021-07-14"))
64
```

```
65
66 #Analise para antes
67 log_antes <- log(antes)
68 diff_antes <- diff(log_antes)
69 serie_antes_diff_ts <- ts(coredata(diff_antes), start = start(diff_antes
70   ), frequency = frequency(diff_antes))
71
72 plot(serie_antes_diff_ts)
73 acf(serie_antes_diff_ts)
74 pacf(serie_antes_diff_ts)
75 acf(serie_antes_diff_ts^2)
76
77
78 #Analise para depois
79
80 log_depois <- log(depois)
81 diff_depois <- diff(log_depois)
82 serie_depois_diff_ts <- ts(coredata(diff_depois), start = start(diff_
83   depois), frequency = frequency(diff_depois))
84
85 plot(serie_depois_diff_ts)
86 acf(serie_depois_diff_ts)
87 pacf(serie_depois_diff_ts)
88 acf(serie_depois_diff_ts^2)
89
90 #ANALISE DESCRITIVA
91
92 # Estat sticas descritivas para 'tudo'
93
94 summary(serie_temporal)
95 sd(serie_temporal, na.rm = TRUE)
96 var(serie_temporal, na.rm = TRUE)
97
98 # Estat sticas descritivas para 'antes'
99 summary(antes)
100 sd(antes, na.rm = TRUE)
101 var(antes, na.rm = TRUE)
102
```

```
103 # Estatísticas descritivas para 'depois'
104 summary(depois)
105 sd(depois, na.rm = TRUE)
106 var(depois, na.rm = TRUE)
107
108
109
110
111 plot(antes)
112 adf.test(antes)
113
114 plot(depois)
115 adf.test(depois)
116
117 ### GARCH ANTES
118
119
120 # Ajustar o modelo GARCH
121 modelo_garch <- ugarchspec(variance.model = list(model = "sGARCH",
122           garchOrder = c(1, 1)), mean.model = list(armaOrder = c(0, 0), include
123           .mean = FALSE), distribution.model = "norm")
124 ajuste_garch1 <- ugarchfit(spec = modelo_garch, data = serie_antes_diff_
125           ts)
126
127 # Resumo do modelo GARCH
128 print(ajuste_garch1)
129
130 #Resíduos
131 residuos_garch1 <- residuals(ajuste_garch1, standardize = TRUE)
132
133 # Teste de Ljung-Box para os K
134
135 Box.test(residuos_garch1, lag = 1, type = "Ljung-Box", fitdf = 0)
136 Box.test(residuos_garch1, lag = 2, type = "Ljung-Box", fitdf = 0)
137 Box.test(residuos_garch1, lag = 3, type = "Ljung-Box", fitdf = 0)
138 Box.test(residuos_garch1, lag = 4, type = "Ljung-Box", fitdf = 0)
139 Box.test(residuos_garch1, lag = 5, type = "Ljung-Box", fitdf = 0)
140 Box.test(residuos_garch1, lag = 6, type = "Ljung-Box", fitdf = 0)
141 Box.test(residuos_garch1, lag = 10, type = "Ljung-Box", fitdf = 0)
142 Box.test(residuos_garch1, lag = 15, type = "Ljung-Box", fitdf = 0)
```

```

140 Box.test(residuos_garch1, lag = 20, type = "Ljung-Box", fitdf = 0)
141
142
143 # Visualiza o: ACF e PACF dos Res duos Padronizados
144 acf(residuos_garch1, main = "ACF dos Res duos Padronizados")
145 pacf(residuos_garch1, main = "PACF dos Res duos Padronizados")
146 #ACF e dos Quadrados dos Res duos Padronizados
147 acf(residuos_garch1^2, main = "ACF dos Quadrados dos Res duos
      Padronizados")
148
149 # Visualiza o: QQ-plot dos Res duos Padronizados
150 qqnorm(residuos_garch1)
151 qqline(residuos_garch1, col = "red")
152
153
154 ### GARCH DEPOIS
155 # Ajustar o modelo GARCH
156 modelo_garch <- ugarchspec(variance.model = list(model = "sGARCH",
      garchOrder = c(1, 1)), mean.model = list(armaOrder = c(0, 0), include
      .mean = FALSE), distribution.model = "norm")
157 ajuste_garch2 <- ugarchfit(spec = modelo_garch, data = serie_depois_diff
      _ts)
158
159 # Resumo do modelo GARCH
160 print(ajuste_garch2)
161
162 #Residuos
163 residuos_garch2 <- residuals(ajuste_garch2, standardize = TRUE)
164
165 # Teste de Ljung-Box para os K
166
167 Box.test(residuos_garch2, lag = 1, type = "Ljung-Box", fitdf = 0)
168 Box.test(residuos_garch2, lag = 2, type = "Ljung-Box", fitdf = 0)
169 Box.test(residuos_garch2, lag = 3, type = "Ljung-Box", fitdf = 0)
170 Box.test(residuos_garch2, lag = 4, type = "Ljung-Box", fitdf = 0)
171 Box.test(residuos_garch2, lag = 5, type = "Ljung-Box", fitdf = 0)
172 Box.test(residuos_garch2, lag = 6, type = "Ljung-Box", fitdf = 0)
173 Box.test(residuos_garch2, lag = 10, type = "Ljung-Box", fitdf = 0)
174 Box.test(residuos_garch2, lag = 15, type = "Ljung-Box", fitdf = 0)
175 Box.test(residuos_garch2, lag = 20, type = "Ljung-Box", fitdf = 0)

```

```
176
177
178 # Visualiza o: ACF e PACF dos Res duos Padronizados
179 acf(residuos_garch2, main = "ACF dos Res duos Padronizados")
180 pacf(residuos_garch2, main = "PACF dos Res duos Padronizados")
181 #ACF e dos Quadrados dos Res duos Padronizados
182 acf(residuos_garch2^2, main = "ACF dos Quadrados dos Res duos
      Padronizados")
183
184 # Visualiza o: QQ-plot dos Res duos Padronizados
185 qqnorm(residuos_garch2)
186 qqline(residuos_garch2, col = "red")
187
188
189
190 # Ajustando diferentes modelos GARCH para compara o
191
192 garch11 <- garchFit(~ garch(1, 1), data = serie_antes_diff_ts, trace =
      FALSE)
193 garch12 <- garchFit(~ garch(1, 2), data = serie_antes_diff_ts, trace =
      FALSE)
194 garch21 <- garchFit(~ garch(2, 1), data = serie_antes_diff_ts, trace =
      FALSE)
195 garch22 <- garchFit(~ garch(2, 2), data = serie_antes_diff_ts, trace =
      FALSE)
196
197 summary(garch11)
198 summary(garch12)
199 summary(garch21)
200 summary(garch22)
```