
Previsão de séries temporais financeiras: as taxas de câmbio EUR/CNY e EUR/USD

Carlos Miguel Cruz Esteves

Mestrado em Matemática Financeira

Orientadora:

Doutora Diana E. Aldea Mendes, Professora Associada,
Departamento de Métodos Quantitativos para Gestão e Economia,
ISCTE-IUL

Outubro, 2022

Departamento de Finanças do Instituto Superior De Ciências do
Trabalho e da Empresa
Departamento de Matemática da Faculdade de Ciências da
Universidade de Lisboa

**Previsão de séries temporais financeiras: as taxas de câmbio EUR/CNY e
EUR/USD**

Carlos Miguel Cruz Esteves

Mestrado em Matemática Financeira

Orientadora:

Doutora Diana E. Aldea Mendes, Professora Associada,
Departamento de Métodos Quantitativos para Gestão e Economia,
ISCTE-IUL

Outubro, 2022

Agradecimentos

Em primeiro lugar quero agradecer à minha orientadora, a Professora Doutora Diana Aldea Mendes, pela ajuda, paciência e disponibilidade ao longo deste trabalho.

Em segundo lugar quero agradecer aos meus amigos, que tiveram a paciência de me ouvir em momentos menos felizes e sempre me apoiaram ao longo do meu percurso universitário. A pandemia não ajudou mas vocês certamente ajudaram. Muito obrigado, do fundo do meu coração.

Em último lugar, e mais importante, quero agradecer à minha família, principalmente aos meus pais. Obrigado pelo amor, carinho e apoio incondicional ao longo da minha vida. Sem eles nada disto seria possível.

Resumo

O presente trabalho tem como principal objetivo estudar séries temporais financeiras, nomeadamente as taxas de câmbio, e identificar o método que apresenta melhores resultados nas suas previsões. Atualmente a análise das taxas de câmbio tem sido um constante desafio, devido à imprevisibilidade das mesmas. Para contornar este problema foram escolhidos instrumentos econométricos específicos com a intenção de encontrar o modelo mais eficiente em prever valores de taxas de câmbio.

Neste estudo foram utilizadas as taxas de câmbio EUR/CNY e EUR/USD, ambas com um total de 242 observações entre janeiro de 2002 e fevereiro de 2022 e ambas com frequência mensal, e os modelos econométricos ARIMA, ARIMA-GARCH e Random Walk, incluindo a utilização do algoritmo Prophet. Foram também selecionadas algumas medidas de erro para comparar as previsões obtidas com os valores reais das séries temporais financeiras.

Da análise feita, concluiu-se que o modelo ARIMA(0,1,1)-GARCH(1,1) apresentou as melhores previsões *in-sample*, para ambas as séries originais. As previsões *out-of-sample* para estas séries não foram as melhores, sendo que o modelo que apresentou a melhor previsão *out-of-sample* foi o ARIMA(0,1,1), para ambos os casos.

Em relação aos retornos, os modelos que apresentaram as melhores previsões *in-sample* para as séries RetLogEURCNY e RetLogEURUSD foram o Prophet e o MA(1), respetivamente. Nas previsões *out-of-sample*, foi o Prophet que apresentou o menor erro de previsão, ainda que elevado, para ambos os casos.

Palavras-chave: Taxa de câmbio EUR/USD; Taxa de câmbio EUR/CNY; Série temporal; Previsão; Modelos ARIMA-GARCH; Prophet

Classificação JEL: C22; C53; C58; G17

Abstract

The main objective of this work is to study financial time series, namely exchange rates, and to identify the method that presents the best results in its forecasts. Currently, the analysis of exchange rates has been a constant challenge, due to their unpredictability. To overcome this problem, specific econometric instruments were chosen with the intention of finding the most efficient model to predict exchange rate values.

In this study, the EUR/CNY and EUR/USD exchange rates were used, both with a total of 242 observations between January 2002 and February 2022 and both at a monthly frequency, and the econometric models used were the ARIMA, ARIMA-GARCH and Random Walk, including the use of the Prophet algorithm. Some error measures were also selected to compare the forecasts with the actual values of both financial time series.

From the analysis, it was concluded that the ARIMA(0,1,1)-GARCH(1,1) model presented the best *in-sample* forecasts, for both original series. The *out-of-sample* forecasts for the original series were not the best, but the model that presented the best *out-of-sample* forecasts was the ARIMA(0,1,1), for both cases.

Regarding the returns, the models that presented the best *in-sample* forecasts for the RetLogEURCNY and RetLogEURUSD series were the Prophet and MA(1), respectively. In the *out-of-sample* forecasts, Prophet presented the smallest forecast error, although high, for both cases.

Keywords: EUR/USD exchange rate; EUR/CNY exchange rate; Time series; Forecast; ARIMA-GARCH models; Prophet

JEL classification: C22; C53; C58; G17

Índice

Agradecimentos	i
Resumo	iii
Abstract.....	v
Lista de Figuras.....	ix
Lista de Tabelas.....	xi
Introdução	1
Capítulo 1. Revisão da Literatura.....	3
1.1. Enquadramento Teórico.....	3
1.2. A moeda Euro.....	6
1.3. Os Estados Unidos da América e o Dólar Americano.....	6
1.3.1. A taxa de câmbio EUR/USD.....	7
1.4. A China e o Renminbi	7
1.4.1. A taxa de câmbio EUR/CNY	8
Capítulo 2. Metodologia.....	11
2.1. Séries Temporais	11
2.1.1. Descrição de séries temporais.....	12
2.2. Estacionariedade.....	13
2.2.1. Testes de Raiz Unitária.....	14
2.3. Modelos Univariados.....	16
2.3.1. Modelos Autoregressivos - $AR(p)$	16
2.3.2. Modelos de Média Móvel - $MA(q)$	17
2.3.3. Modelos Autoregressivos de Médias Móveis - $ARMA(p, q)$	17
2.3.4. Modelos Autoregressivos Integrados de Médias Móveis - $ARIMA(p, d, q)$..	17
2.3.5. A Metodologia de Box-Jenkins	18
2.4. Modelos ARCH/GARCH.....	18
2.4.1. O modelo GARCH.....	19
2.5. Random Walk sem drift.....	20
2.6. Previsão	20
2.6.1. Erro de Previsão	20
Capítulo 3. Análise Empírica	23

3.1. Análise das Séries Temporais	23
3.1.1. Estacionariedade	25
3.2. Análise das Séries - Retornos Logarítmicos	26
3.2.1. Estacionariedade das séries dos retornos logarítmicos	28
3.3. Estimação dos Modelos Univariados	28
3.4. Análise dos Resíduos	29
3.5. Previsão	31
3.5.1. Previsões das séries originais	31
3.5.2. Previsões <i>in-sample</i> para as séries originais	33
3.5.3. Previsões <i>out-of-sample</i> para as séries originais	36
3.5.4. Previsões das séries em diferenças logaritmizadas	37
3.5.5. Previsões <i>in-sample</i> para as séries em diferenças logaritmizadas	39
3.5.6. Previsões <i>out-of-sample</i> para as séries em diferenças logaritmizadas	41
Conclusões	43
Referências Bibliográficas	45
Anexos	47
Anexo A	47
Anexo B	48
Anexo C	49
Anexo D	50
Anexo E	51
Anexo F	52
Anexo G	53
Anexo H	54
Anexo I	55
Anexo J	57

Lista de Figuras

Figura 1.1	Histórico diário da taxa de câmbio EUR/USD entre 1999 a 2022	7
Figura 1.2	Histórico diário da taxa de câmbio EUR/CNY entre 2000 e 2022.....	8
Figura 3.1	Representação gráfica da série EUR/CNY	23
Figura 3.2	Representação gráfica da série EUR/USD	24
Figura 3.3	Representação gráfica dos retornos da série EUR/CNY (RetLogEURCNY)	26
Figura 3.4	Representação gráfica dos retornos da série EUR/USD (RetLogEURUSD)	26
Figura 3.5	Funções ACF e PACF para a série RetLogEURCNY	29
Figura 3.6	Funções ACF e PACF para a série RetLogEURUSD.....	29
Figura 3.7	Valores ajustados do modelo ARIMA(0,1,1) para o conjunto de treino da série EUR/CNY	32
Figura 3.8	Valores ajustados do modelo ARIMA(0,1,1) para o conjunto de treino da série EUR/USD	32
Figura 3.9	Previsão de valores da série EUR/CNY com vários modelos econométricos	34
Figura 3.10	Previsão de valores da série EUR/USD com vários modelos econométricos	35
Figura 3.11	Valores ajustados do modelo MA(1) para o conjunto de treino da série RetLogEURCNY	38
Figura 3.12	Valores ajustados do modelo MA(1) para o conjunto de treino da série RetLogEURUSD.....	38
Figura 3.13	Previsão de valores da série RetLogEURCNY com vários modelos econométricos	39
Figura 3.14	Previsão de valores da série RetLogEURUSD com vários modelos econométricos	40
Figura 3.15	Modelo MA(1) para a série RetLogEURCNY.....	47
Figura 3.16	Modelo MA(1) para a série RetLogEURUSD	48
Figura 3.17	Modelo ARIMA(0,1,1) para o conjunto de treino da série EUR/CNY .	49
Figura 3.18	Modelo ARIMA(0,1,1) para o conjunto de treino da série EUR/USD..	49
Figura 3.19	Modelo GARCH(1,1) para os resíduos do modelo ARIMA(0,1,1) da série EUR/CNY (conjunto de treino).....	50

Figura 3.20	Modelo GARCH(1,1) para os resíduos do modelo ARIMA(0,1,1) da série EUR/USD (conjunto de treino)	50
Figura 3.21	Modelo MA(1) para o conjunto de treino da série RetLogEURCNY....	53
Figura 3.22	Modelo MA(1) para o conjunto de treino da série RetLogEURUSD	53
Figura 3.23	Modelo GARCH(1,1) para os resíduos do modelo MA(1) da série RetLogEURCNY (conjunto de treino)	54
Figura 3.24	Modelo GARCH(1,1) para os resíduos do modelo MA(1) da série RetLogEURUSD (conjunto de treino)	54

Lista de Tabelas

Tabela 3.1	Estatísticas Descritivas das séries EUR/CNY e EUR/USD	24
Tabela 3.2	Teste de Normalidade de Jarque-Bera para as séries EUR/CNY e EUR/USD	25
Tabela 3.3	Testes de Estacionariedade para a série EUR/CNY	25
Tabela 3.4	Testes de Estacionariedade para a série EUR/USD.....	25
Tabela 3.5	Estatísticas Descritivas para os retornos das séries EUR/CNY e EUR/USD	27
Tabela 3.6	Teste de Normalidade de Jarque-Bera para os retornos das séries EUR/CNY e EUR/USD.....	27
Tabela 3.7	Testes de Estacionariedade para a série RetLogEURCNY	28
Tabela 3.8	Testes de Estacionariedade para a série RetLogEURUSD	28
Tabela 3.9	Primeiro Pressuposto dos Resíduos – Valor Médio Nulo	30
Tabela 3.10	Resultados do Teste de <i>Ljung-Box</i>	30
Tabela 3.11	Resultados do Teste ARCH	30
Tabela 3.12	Valores das Medidas de Erro para os valores ajustados pelo modelo ARIMA(0,1,1) do conjunto de treino das séries EUR/CNY e EUR/USD.....	32
Tabela 3.13	Valores das medidas de erros das previsões para a série EUR/CNY	34
Tabela 3.14	Valores das medidas de erros das previsões para a série EUR/USD.....	35
Tabela 3.15	<i>Performance</i> das previsões <i>out-of-sample</i> para a série EUR/CNY.....	36
Tabela 3.16	<i>Performance</i> das previsões <i>out-of-sample</i> para a série EUR/USD	37
Tabela 3.17	Valores das Medidas de Erro para os valores ajustados do conjunto de treino das séries RetLogEURCNY e RetLogEURUSD	38
Tabela 3.18	Valores das medidas de erro das previsões para a série RetLogEURCNY	40
Tabela 3.19	Valores das medidas de erro das previsões para a série RetLogEURUSD	41
Tabela 3.20	<i>Performance</i> da previsão <i>out-of-sample</i> para a série RetLogEURCNY	41
Tabela 3.21	<i>Performance</i> da previsão <i>out-of-sample</i> para a série RetLogEURUSD	42
Tabela 3.22	Valores previstos por cada modelo para a série EUR/CNY	51
Tabela 3.23	Valores previstos por cada modelo para a série EUR/USD	52
Tabela 3.24	Valores previstos por cada modelo para a série RetLogEURCNY.....	56

Tabela 3.25	Valores previstos por cada modelo para a série RetLogEURUSD	58
-------------	---	----

Introdução

Devido à crescente globalização presenciada nas últimas décadas, a importância dos mercados cambiais e das taxas cambiais nas economias mundiais tem crescido exponencialmente, já que os próprios governos são participantes neste tipo de mercado. No entanto, o estudo e previsão dos valores cambiais neste mercado tem sido um difícil desafio para os seus participantes, devido à própria natureza das taxas cambiais.

O objetivo da presente dissertação é analisar e prever séries temporais, nomeadamente séries que expressem valores das taxas de câmbio EUR/CNY e EUR/USD. Este estudo será feito com o auxílio de instrumentos econométricos, incluindo modelos que conseguem prever valores de séries temporais. Deste modo, este trabalho dividiu-se em quatro partes.

No Capítulo 1 é realizada uma revisão geral da literatura sobre o tema e sua importância no mundo atual. Numa primeira fase é explicado o conceito de taxa de câmbio e as suas características. De seguida é feito um enquadramento, recorrendo a estudos que utilizam modelos econométricos para prever valores de séries temporais, incluindo previsões de taxas de câmbio. Por último, é feito um enquadramento teórico sobre a moeda Euro, o Dólar Americano e o Renminbi Chinês e uma história sintetizada das mesmas, inclusive a evolução diária dos valores das taxas de câmbio EUR/CNY e EUR/USD.

O Capítulo 2 é o suporte teórico da dissertação e é dividido em três partes. Numa primeira fase são apresentadas as séries temporais e conceitos econométricos como estacionariedade e testes de raiz unitária. De seguida são apresentados os modelos que irão ser utilizados para prever os valores das taxas de câmbio em estudo. Por último, é introduzido o conceito de previsão e é explicado o erro de previsão, incluindo as medidas de erro que irão ser utilizadas para comparar os valores previstos dos modelos escolhidos com os valores reais das séries temporais.

O Capítulo 3 é reservado exclusivamente para o estudo empírico das taxas de câmbio EUR/CNY e EUR/USD. Neste capítulo serão aplicados os conhecimentos teóricos presentes no Capítulo 2, sendo que cada resultado irá ser analisado e interpretado com o auxílio da linguagem de programação *Python* e o *Jupyter Notebook*.

Por fim, é realizada uma síntese do estudo, onde será apresentada uma comparação entre os valores previstos pelos modelos escolhidos, e onde será indicado qual dos modelos é o mais adequado para prever as taxas de câmbio em estudo.

CAPÍTULO 1

Revisão da Literatura

1.1. Enquadramento Teórico

As taxas de câmbio têm vindo a desempenhar funções cruciais na estabilidade e no crescimento económico de países, muito devido à globalização presenciada nas últimas décadas, tendo, assim, uma grande influência tanto em economias internas como em economias internacionais. Devido à crescente importância deste tema nos tempos de hoje, é essencial estudar e tentar prever o comportamento futuro das mesmas, com o auxílio de determinados modelos econométricos. Contudo, a previsão destes valores tem sido um constante desafio, já que as taxas cambiais são voláteis e os resultados obtidos por esses modelos poderão não ser os esperados.

“As taxas de câmbio têm protagonizado um tema predominante na discussão política entre países desenvolvidos ao longo dos anos. No mundo atual, as taxas de câmbio referentes aos países mais bem sucedidos economicamente tendem a oscilar ao longo do tempo. Este acontecimento prende-se com o facto de cada moeda ser afetada pelo mercado cambial, o que origina valorizações e desvalorizações, que por sua vez, podem ser constantes ou momentâneas.

Hoje em dia, as taxas de câmbio são reconhecidas como um vínculo decisivo entre a economia interna de um país e a economia internacional, onde a teoria por detrás dedica-se, principalmente, a entender o nível, ou pelo menos a fator de mudança, presente nas flutuações constantes das taxas de câmbio.”

(Marques, 2017, p. 3)

Em primeiro lugar é necessário introduzir o conceito de taxa de câmbio. Uma taxa de câmbio representa o valor de conversão de uma moeda na outra, isto é, uma taxa de câmbio assinala o preço de uma moeda em termos de outra. De acordo com a base de dados do Banco Central Europeu, no dia 6 de maio de 2022 a taxa de câmbio EUR/USD foi 1.057. Isto significa que, nesse dia, para adquirir 1 Euro seriam necessários 1.057 Dólares Americanos.

As oscilações dos valores das taxas de câmbio são descritas como apreciações ou depreciações de uma moeda em relação a outra. Utilizando o exemplo anterior, se no dia a seguir o valor da taxa de câmbio EUR/USD for abaixo do valor observado no dia anterior,

significa que o Euro depreciou em relação ao Dólar Americano, já que são necessárias menos unidades de Dólar Americano para adquirir uma unidade de Euro. Uma depreciação monetária significa que os bens desse país ficaram mais baratos para os agentes externos, isto é, com a depreciação do Euro, os bens europeus ficaram mais baratos para os agentes norte-americanos, mantendo tudo o resto constante. Caso aconteça o inverso, ou seja, se o valor do dia seguinte for mais elevado do que o valor observado no dia anterior, significa que o Euro apreciou em relação ao Dólar Americano, pois são necessárias mais unidades de Dólar Americano para a obtenção de uma unidade de Euro. Uma apreciação também significa que os bens desse país ficaram mais caros para os agentes externos, isto é, com a apreciação do Euro, os bens europeus ficaram mais caros para os agentes norte-americanos, mantendo tudo o resto constante.

Segundo Mota (2017), as taxas de câmbio representam um preço de equilíbrio entre a procura e oferta dessa relação de troca nos mercados cambiais.

As transações entre moedas ocorrem no mercado cambial, ou FOREX. O mercado cambial não é um mercado físico, mas um mercado digital e aberto a qualquer hora do dia e a qualquer dia da semana. Este mercado é considerado um dos maiores mercados financeiros a nível mundial, devido ao volume de transações diárias. Existem várias entidades que participam no mercado cambial, como os governos, bancos e investidores, tanto institucionais (empresas) como individuais.

A própria natureza das taxas de câmbio torna a previsão das mesmas um grande desafio. No entanto, ao longo dos anos, foram desenvolvidos modelos econométricos com o propósito de prever estes valores. É essencial referir que estes modelos tratam as taxas de câmbio como séries temporais. Um dos modelos mais utilizados é o modelo Autoregressivo Integrado de Médias Móveis (ARIMA), pois apresenta valores precisos no que toca à previsão de séries temporais. É importante saber que este tipo de modelo assume variância constante nos erros (homocedasticidade).

Farhan e Fakhir (2019) utilizaram um modelo ARIMA para o seu estudo da taxa de câmbio do Dinar Iraquiano face ao Dólar Americano. Foi observado que as previsões da taxa de câmbio a partir do modelo ARIMA (1,1,1) foram superiores às previsões dos restantes modelos do tipo ARIMA analisados, já que apresentaram *Mean Absolute Error* (MAE) e *Root Mean Squared Error* (RMSE) inferiores em comparação com os restantes modelos estudados.

Olakorede, Olanrewaju e Ugbede (2018) estudaram a taxa de câmbio entre a Naira Nigeriana e o Dólar Americano. Mais uma vez, foi utilizado um modelo do tipo ARIMA, neste caso um modelo ARIMA(0,1,1), para prever os próximos valores da taxa de câmbio. Os autores chegaram à conclusão que a Naira Nigeriana iria continuar a depreciar em relação ao Dólar Americano.

Marques (2017) utiliza os modelos de tipo ARIMA para fazer previsões da taxa de câmbio EUR/USD. O autor utiliza dados mensais e diários para fazer a sua comparação

com outros modelos. Nos dados diários foi escolhido um modelo ARIMA (2,1,2) e nos dados mensais foi escolhido um modelo ARIMA (1,1,2). Os valores previstos pelos modelos ARIMA apresentaram erros de previsão e RMSE inferiores quando comparado aos restantes modelos testados, o que significa que os modelos ARIMA escolhidos conseguiram prever com maior precisão, de acordo com as métricas de erro utilizadas.

Plakandaras, Papadimitriou e Gogas (2015) implementaram vários tipos de modelos, incluindo o modelo ARIMA, e produziram previsões *in-sample* e *out-of-sample* para várias taxas de câmbio: EUR/USD, USD/JPY, AUD/NOK, NZD/BRL e ZAR/PHP¹. Como forma de comparação entre a *performance* das previsões foram utilizados dados diários e dados mensais. Os autores chegaram à conclusão que as previsões diárias dos modelos ARIMA para cada par de divisas apresentaram um erro mais baixo do que as previsões dos dados mensais, tanto para as previsões *in-sample* como para as previsões *out-of-sample*.

Existem outros modelos utilizados com o intuito de prever séries temporais. Os modelos ARCH/GARCH são muitas vezes utilizados já que, ao contrário do modelo ARIMA, não assumem variância constante ao longo do tempo, conseguindo captar a volatilidade de séries temporais.

Sharma, Yadav e Jha (2022) utilizaram o modelo GARCH para estudar o impacto da pandemia do COVID-19 em diversas taxas de câmbio: EUR/USD, USD/JPY, GBP/USD, AUD/USD, USD/CAD, USD/CHF e CHF/JPY². Os autores concluíram que a pandemia teve um impacto negativo nas taxas de câmbio USD/JPY, AUD/USD e USD/CHF, e um impacto positivo nos pares de divisas EUR/USD, GBP/USD, USD/CAD e CHF/JPY.

Uma extensão dos modelos anteriormente falados é o modelo ARIMA-GARCH. Como os modelos ARIMA apresentavam a limitação de homocedasticidade, era necessário a utilização de um modelo que contrariasse essa falha e introduzir a hipótese de heterocedasticidade nos resíduos do modelo. Para solucionar o problema foi feita a incorporação do modelo ARIMA com o modelo GARCH, o que possibilita a integração da volatilidade presente nos ativos financeiros. Neste tipo de modelos, a equação da média é obtida através do modelo ARIMA e a equação da variância é obtida através do modelo GARCH. As previsões são realizadas em ambas as equações e depois irão ser somadas, um procedimento não muito frequente quando se utilizam modelos híbridos ARIMA-GARCH, criando a previsão deste modelo.

Um exemplo de aplicação do modelo ARIMA-GARCH em séries temporais foi feito por Mustapa e Ismail (2019). O objetivo do estudo era analisar os valores mensais entre 2001 e 2017 do S&P 500 e encontrar o modelo ARIMA-GARCH que melhor se enquadrava com os dados. Os autores chegaram à conclusão de que o modelo ARIMA(2,1,2)-GARCH(1,1) foi o que apresentava as melhores previsões do S&P 500.

Por último, e uma criação mais recente, as previsões podem ser efetuadas com a utilização de um algoritmo chamado de Prophet. O Prophet é um algoritmo de código

¹USD: Dólar Americano; JPY: Iene Japonês; AUD: Dólar Australiano; NOK: Coroa Norueguesa; NZD: Dólar Neozelandês; BRL: Real Brasileiro; ZAR: Rand Sul-Africano; PHP: Peso Filipino

²GBP: Libra Esterlina; CAD: Dólar Canadiano; CHF: Franco Suíço

em linguagem *Python* lançado pela equipa de Core Data Science do Facebook, com o objetivo de facilitar previsão de séries temporais, conseguindo prever de uma forma rápida e precisa.

Kolari e Sanz (2022) utilizaram o algoritmo Prophet com o objetivo de prever os rácios de capital bancário para 19 grandes bancos americanos, usando dados entre março de 2005 e dezembro de 2020. Os resultados *in-sample* mostraram que o modelo estima com precisão estes rácios e os resultados *out-of-sample* indicaram que os erros de previsão são menores nos valores previstos pelo Prophet comparativamente aos modelos ARIMAX, sendo este um modelo ARIMA que incorpora na sua expressão variáveis exógenas.

1.2. A moeda Euro

A moeda Euro ainda é relativamente recente. O planeamento do lançamento de uma moeda única começou em fevereiro de 1992, com o assinado do Tratado da União Europeia, em Maastricht. Após quase 7 anos de planeamento cuidado e rigoroso, a moeda foi lançada no dia 1 de janeiro de 1999, em termos virtuais, utilizada sobretudo em mercados financeiros e por entidades bancárias, para facilitar a transição. Em termos físicos, a moeda Euro só foi lançada em circulação no dia 1 de janeiro de 2002, em 11 países, chamados de membros fundadores, entre eles Portugal. Atualmente, a Zona Euro é composta por 19 membros da União Europeia, de 27 possíveis. É importante mencionar que os países da União Europeia que decidam aderir à moeda única devem cumprir certas condições económicas e jurídicas vinculativas, chamadas de critérios de convergência, presentes no Tratado de Maastricht.

1.3. Os Estados Unidos da América e o Dólar Americano

O Dólar Americano é a referência mundial em termos cambiais, isto devido à criação do Sistema de Bretton Woods. Este sistema monetário internacional foi implementado em julho de 1944 por delegados de 44 nações com o objetivo de evitar a rigidez dos sistemas monetários anteriores, incentivar a cooperação entre os países inseridos no sistema e controlar o valor da moeda de cada membro. Os delegados também concordaram em criar o Fundo Monetário Internacional (FMI) e o agora conhecido como Banco Mundial. O FMI tinha como objetivo de monitorizar as taxas de câmbio de cada país e emprestar reservas a países que apresentassem um déficit na balança de pagamentos. O Banco Mundial tinha como principal responsabilidade fornecer assistência financeira após a Segunda Guerra Mundial e prestar auxílio no desenvolvimento económico dos países menos desenvolvidos. O FMI entrou em funcionamento no final de 1945 e os países que assinaram os seus *Articles of Agreement* acordaram em manter as suas moedas fixas, contudo ajustáveis ao Dólar Americano, com ajustamento máximo na faixa do 1%. O Dólar Americano também foi fixado, neste caso ao preço do ouro, em 35 USD por onça. O Dólar Americano tornou-se assim num ponto crítico deste sistema, já que influenciava não só a economia americana mas também as economias internacionais inseridas neste sistema.

Mais tarde, em 1971, o Sistema de Bretton Woods foi suspenso pelo então Presidente norte-americano Richard Nixon, devido a uma acumulação de deficits na balança de pagamentos e também ao esgotamento das reservas de ouro nos EUA. Em 1973, este sistema foi encerrado e deu-se origem às taxas cambiais flutuantes. Sem o controlo de preços, o ouro subiu consideravelmente, atingindo o valor de 120 Dólares Americanos por onça.

1.3.1. A taxa de câmbio EUR/USD

A taxa de câmbio EUR/USD é considerada uma das taxas de câmbio mais importantes, devido à presença das duas moedas mais transacionadas em todo o mundo, o Euro e o Dólar Americano.

A figura seguinte mostra a evolução dos valores diários da taxa de câmbio EUR/USD para o período entre 04-01-1999 e 28-02-2022.




FIGURA 1.1. Histórico diário da taxa de câmbio EUR/USD entre 1999 a 2022

Ao analisar o histórico diário da taxa cambial EUR/USD observa-se, após a implementação do Euro, uma quebra no valor da taxa de câmbio, ou seja, o Dólar Americano apreciou em relação ao Euro, sendo que existe um período em que este valor fica abaixo de 1 Dólar Americano, isto é, o Dólar Americano tornou-se mais valioso que o Euro. Entre 2000 e 2008 o valor de taxa de câmbio cresce de uma forma quase constante e atinge o seu máximo em 2008, frutos da crise financeira do *subprime*. Após a crise de 2008 e até 2022, o valor decresce de uma forma global, com subidas e descidas durante esse período. É também importante referir a existência de uma subida neste valor durante o início de 2020, face à pandemia do COVID-19.

1.4. A China e o Renminbi

A economia chinesa abriu as suas portas ao mundo com uma reforma no final do ano de 1978. Com isto, o Produto Interno Bruto (PIB) chinês cresceu, em média, quase 10 pontos percentuais por ano durante cerca de 30 anos. Devido a este crescimento,

cerca de 800 milhões de pessoas saíram da situação de pobreza no país e outros setores chineses melhoraram significativamente, como a saúde e a educação. Este crescimento económico deve-se principalmente ao baixo preço da mão-de-obra, às exportações e à própria produção com utilização intensiva de recursos, o que levou a um desequilíbrio nas áreas sociais, económicas e ambientais. É importante referir que antes da reforma, a economia chinesa estava fora das oito maiores economias mundiais. Atualmente é a segunda maior economia do mundo, apenas atrás dos Estados Unidos da América e, a este ritmo, é esperado que a China ultrapasse os Estados Unidos ainda antes do final deste século.

Este rápido crescimento económico também trouxe algumas consequências negativas, nomeadamente no setor ambiental. Atualmente a China é o país que apresenta a maior taxa de emissão de gases com efeitos estufa a nível mundial, com emissões *per capita* que ultrapassam o total da União Europeia.

O Renminbi é a moeda chinesa, no entanto existem dois tipos de Renminbi: o CNY e o CNH. O CNY é o Renminbi trocado na China continental, enquanto o CNH é o Renminbi trocado *offshore*, como por exemplo em Hong Kong. A grande diferença entre os dois tipos é que o CNY é controlado pelo governo enquanto o CNH foi criado para ser negociado livremente e é controlado apenas pelo mercado livre, que determina o seu valor. A presente dissertação focar-se-á apenas no tipo CNY.

1.4.1. A taxa de câmbio EUR/CNY

A Figura 1.2 mostra a evolução dos valores diários da taxa de câmbio EUR/CNY para o período entre 13-01-2000 a 28-02-2022. Ao analisar o histórico diário da taxa de câmbio




FIGURA 1.2. Histórico diário da taxa de câmbio EUR/CNY entre 2000 e 2022

EUR/CNY observa-se uma quebra na mesma, tal como aconteceu na taxa de câmbio EUR/USD, no entanto esta quebra é mais acentuada, sendo que o valor passa de cerca de 8.500 CNY por uma unidade de Euro na data inicial para cerca de 6.800 CNY por 1 EUR.

aproximadamente em 2001, o que implica uma desvalorização acentuada da moeda Euro em relação ao Renminbi neste período. Após esta quebra, o valor desta taxa de câmbio cresce de uma forma quase constante e atinge o seu máximo aproximadamente em 2005, na qual o valor desta taxa passa a barreira dos 11.000 Yuan por unidade de Euro. Após a crise de 2008, o valor da taxa de câmbio decresce acentuadamente e aproximadamente em 2015, atinge o seu valor mais baixo (cerca de 6.600 Yuan por uma unidade de Euro). Após esta data, o valor da taxa de câmbio EUR/CNY volta a crescer de uma forma quase constante. É também importante referir a existência de uma quebra neste valor no início da pandemia do COVID-19.

CAPÍTULO 2

Metodologia

Antes de analisar e interpretar as abordagens práticas presentes no próximo capítulo, é importante introduzir alguns conceitos teóricos essenciais com o objetivo de entender os tópicos em estudo.

Em primeiro lugar será feita uma introdução sucinta sobre a definição e características de uma série temporal.

De seguida irá ser abordado o conceito de estacionariedade e a sua importância para o estudo de séries temporais.

Após isto, serão introduzidos os modelos univariados para as séries temporais, como o modelo ARMA/ARIMA e o modelo GARCH, incluindo o modelo híbrido ARIMA-GARCH.

Por último será abordado o conceito de previsão, utilizando os modelos univariados referidos no ponto acima, e formas de comparação entre valores previstos pelos modelos e os valores reais de uma série temporal.

A elaboração do presente capítulo será assistida nomeadamente pelos livros de Brooks (2019) e Mills (2019), já que ambos apresentam uma excelente base teórica para o desenvolvimento deste capítulo.

2.1. Séries Temporais

Uma série temporal é um conjunto de observações que aparecem numa forma sequencial, normalmente com um intervalo temporal fixo entre as observações. Esses intervalos temporais podem ser diários, semanais, mensais, etc., sendo que a ordem das observações é crucial no estudo de séries temporais.

Em termos matemáticos, uma série temporal pode ser definida como discreta

$$Y_t \text{ (discreta), } t = 1, 2, \dots, T$$

ou pode ser definida como contínua

$$Y(t) \text{ (contínua), } t \in T \subseteq \mathbb{R}.$$

As séries temporais que apresentam uma única observação para um determinado momento temporal caracterizam-se como séries temporais univariadas, em contrapartida as que apresentam duas ou mais observações por instante no tempo são chamadas de séries temporais multivariadas. Esta dissertação irá abordar apenas o estudo de séries temporais univariadas.

Cada série temporal contém 4 componentes/movimentos principais: movimentos ou variações por estações (sazonalidade), movimentos ou variações cíclicas, movimentos de tendência e movimentos irregulares ou aleatórios.

Os movimentos de tendência são movimentos que se referem à direção global na qual a série temporal se desenvolve, num determinado período temporal. Este tipo de movimento pode ser determinado através de uma regressão linear.

Os movimentos ou variações cíclicas são variações de longo prazo periódicos ou não periódicos em torno da curva de tendências. Um bom exemplo de variações cíclicas é o ciclo dos negócios, pois apresentam períodos de recessão, depressão, prosperidade e recuperação.

Os movimentos ou variações por estações referem-se a movimentos iguais ou similares que a série apresenta durante os mesmos períodos temporais consecutivos. Um exemplo de sazonalidade é o crescimento nas vendas de protetor solar durante o verão.

Os movimentos irregulares ou aleatórios referem-se aos desvios esporádicos das séries temporais, instigados por fatores externos como epidemias ou guerras. Estes desvios provocam variações durante um curto intervalo, no entanto estas variações poderão ser tão intensas ao ponto de criar movimentos cíclicos ou de outra natureza.

2.1.1. Descrição de séries temporais

Para examinar melhor as séries temporais existem estatísticas que ajudam o analista a ter uma melhor interpretação das características que a série apresenta.

Um processo estocástico é definido por qualquer família de variáveis aleatórias, $Y(t)$, $t \in T$, na qual T corresponde a um período de tempo predefinido.

Seja $Y(t)$ um processo estocástico com variância finita para todo o $t \in T$, as suas principais estatísticas definem-se em:

- Média ou Valor Esperado, $\mu(t)$, em que: $\mu(t) = E[Y(t)]$
- Variância, $\sigma^2(t)$, em que: $\sigma^2(t) = Var[Y(t)] = E[(Y(t) - \mu(t))^2]$
- Covariância, $\gamma(t_1, t_2)$, em que: $\gamma(t_1, t_2) = cov[Y(t_1), Y(t_2)] = E\{[Y(t_1) - \mu(t_1)][Y(t_2) - \mu(t_2)]\} = E[Y(t_1)Y(t_2)] - \mu(t_1)\mu(t_2)$
- Correlação, $\rho(t_1, t_2)$, em que: $\rho(t_1, t_2) = \frac{\gamma(t_1, t_2)}{\sigma(t_1)\sigma(t_2)} = \frac{cov[Y(t_1), Y(t_2)]}{\sqrt{Var[Y(t_1)]Var[Y(t_2)]}}$

Assimetria

A assimetria é uma das medidas frequentemente usadas na análise de dados financeiros. Em termos estatísticos, a assimetria mostra o grau de afastamento que uma determinada distribuição apresenta do seu eixo de simetria. Para calcular o coeficiente de simetria, s_k , utiliza-se a fórmula:

$$s_k = \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^3}{\sqrt{[\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2]^3}} \quad (2.1)$$

onde n representa o número de observações da série temporal, y_i é o valor observado da mesma no momento i e $\bar{y}$ é a média amostral.

Depois de calculado o valor do coeficiente de simetria, existem três conclusões possíveis relativamente a esse valor. Se o coeficiente de simetria for igual a zero, significa que a distribuição é simétrica e a Média=Mediana=Moda. Se o coeficiente for positivo, a distribuição é assimétrica positiva (à direita), ou seja, Média $\geq$ Mediana $\geq$ Moda. Por

último, no caso em que o coeficiente é negativo, a distribuição é assimétrica negativa (à esquerda), o que significa que Média $\leq$ Mediana $\leq$ Moda.

Curtose

Em termos estatísticos, a curtose refere-se ao grau de achatamento da distribuição de uma série temporal em relação a uma curva normal de referência. Para calcular o coeficiente de curtose (k) utiliza-se a fórmula:

$$k = \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^4}{(\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2)^2} \quad (2.2)$$

Após o cálculo do coeficiente de curtose, existem 3 classificações possíveis: se o coeficiente for igual a 3, a distribuição é mesocúrtica; no caso do coeficiente ser superior a 3, a distribuição é leptocúrtica; por último, caso o coeficiente for inferior a 3, a distribuição é platicúrtica.

2.2. Estacionariedade

A análise da estacionariedade de uma série temporal é um passo fulcral no estudo das mesmas, já que é uma condição essencial para a utilização de alguns modelos e para a previsão das séries temporais.

Existem dois tipos de estacionariedade: estacionariedade estrita (forte) ou estacionariedade fraca. Um processo estocástico diz-se estritamente estacionário se as suas propriedades não são afetadas por mudanças no tempo (Mills, 2019).

Quando se prova estacionariedade, geralmente refere-se a estacionariedade fraca, já que é difícil achar uma série temporal estritamente estacionária.

Um processo estocástico $\{Y(t), t \in T\}$ diz-se *fracamente estacionário* se, $\forall t \in T$, se tem:

- $E[Y(t)] = \mu$
- $Var(Y(t)) = \sigma^2 < \infty$
- $Cov(Y(t_1), Y(t_2)) = \gamma(t_1, t_2) = \gamma(|t_2 - t_1|), t_1, t_2 \in T$

Então, uma série temporal é *fracamente estacionária* se a sua média for constante ao longo do tempo, se a sua variância for constante e finita ao longo do tempo e se a sua covariância entre os valores desfasados desta série depender apenas do valor da distância temporal entre eles. Uma série temporal que não verifique estes critérios diz-se não-estacionária. Além disso, uma série temporal *estritamente estacionária* significa que ela é automaticamente *fracamente estacionária*, no entanto o contrário pode não se verificar (Mills, 2019).

Quando não se verifica estacionariedade numa série temporal existem certos procedimentos que poderão ajudar a estabilizar as mesmas e torná-las estacionárias:

Diferenças Sucessivas

$$\text{Primeira diferença: } \Delta Y_t = Y_t - Y_{t-1} \quad (2.3)$$

$$\text{Segunda diferença: } \Delta^2 Y_t = Y_t - 2Y_{t-1} + Y_{t-2} \quad (2.4)$$

Diferenças Logaritmizadas

$$\Delta \log(Y_t) = \log(Y_t) - \log(Y_{t-1}) \quad (2.5)$$

Se uma série não-estacionária for diferenciada d vezes antes de se tornar estacionária, diz-se que essa série é integrada de ordem d , denotada por $Y_t \sim I(d)$. Uma série estacionária que não necessite de ser diferenciada diz-se que é integrada de ordem 0, $I(0)$.

Ruído Branco

Um processo $\{\varepsilon_t\}$ define-se como ruído branco se:

- $E[\varepsilon_t] = 0$
- $Var[\varepsilon_t] = \sigma^2 < \infty$
- $E[\varepsilon_j, \varepsilon_k] = 0, j \neq k$

Então, um processo define-se como ruído branco se tiver média nula, variância constante e finita e não apresentar correlação serial. Um processo de ruído branco representa-se por $\varepsilon_t \sim WN(0, \sigma^2)$. Para além disso, os erros de modelos devem ser ruídos brancos, já que o ideal é não existir correlação entre eles. Se os erros forem correlacionados, a modelização e previsão de valores poderão não ser confiáveis.

As séries temporais podem apresentar dois tipos de tendência: tendência determinística, em que existem variações aleatórias em torno da curva de tendência, não impactando o comportamento do processo no longo prazo, ou tendência estocástica, em que a componente aleatória ε_t influencia o comportamento da série no longo prazo.

Considera-se o seguinte modelo

$$Y_t = \rho Y_{t-1} + \beta_0 + \beta_1 t + \varepsilon_t \quad (2.6)$$

e os seguintes cenários:

- Se $\rho = 0$, significa que temos um processo estocástico em tendência puro (desenvolve-se em torno de uma tendência linear – média não constante), ou seja, existe uma tendência determinística. Neste caso, a série é não-estacionária;
- Se $\rho = 1$ e $\beta_1 = 0$ então temos um processo estocástico em diferenças puro, também denominado por passeio aleatório com *drift*, logo existe uma tendência estocástica. Neste caso, a série é não-estacionária;
- Se $\rho = 1$ e $\beta_0, \beta_1 \neq 0$, significa que o processo estocástico é um passeio aleatório com *drift* e tendência determinística. A série é não-estacionária;
- Se $0 < \rho < 1$, significa que existe correlação serial em Y , mas não existe tendência estocástica. A série é estacionária.

Para sintetizar, o estudo da não-estacionariedade de uma série é analisar se $\rho = 1$. Caso se verifique, a série apresenta uma raiz unitária e é não-estacionária.

2.2.1. Testes de Raiz Unitária

Geralmente as séries temporais são não-estacionárias, no entanto esta característica tem de ser provada. Para este estudo foram usados testes para detetar se a série temporal

é estacionária ou não. Se a série não for estacionária diz-se que tem uma raiz unitária. É então testada a hipótese nula de que a série é não-estacionária ($H_0: \rho = 1$, a série é não-estacionária) *versus* a hipótese de que a série é estacionária ($H_1: \rho \neq 1$, a série é estacionária).

Existem vários testes de raiz unitária, no entanto os mais frequentes são: o teste DF (Dickey-Fuller), o teste ADF (Augmented Dickey-Fuller), o teste PP (Phillips-Perron) e o teste KPSS (Kwiatkowski-Phillips-Schmidt-Shin).

O teste de Dickey-Fuller é utilizado quando se assume que os erros (ε_t) são ruído branco, isto é, quando os erros são independentes e não apresentam autocorrelação. Ao utilizar o modelo previamente exemplificado, presente na equação (2.6), subtrai-se Y_{t-1} em ambos os lados da equação:

$$\Delta Y_t = (\rho - 1)Y_{t-1} + \beta_0 + \beta_1 t + \varepsilon_t \quad (2.7)$$

Para o teste DF, as hipóteses testadas são as seguintes:

$$H_0: \rho = 1 \text{ (existência de uma raiz unitária)}$$

versus

$$H_1: \rho < 1 \text{ (não existência de uma raiz unitária)}$$

A condição de não correlação serial entre os erros nem sempre é verificada, portanto é necessário um teste que faça a correção paramétrica. Este teste é chamado de teste de Dickey-Fuller Aumentado (ADF), onde a regressão é aumentada em ΔY_{t-i} termos, ao ponto de garantir erros não autocorrelacionados. O modelo de exemplo modifica-se novamente:

$$\Delta Y_t = (\rho - 1)Y_{t-1} + \sum_{i=1}^p \beta_i \Delta Y_{t-i} + \varepsilon_t \quad (2.8)$$

As hipóteses referentes ao teste ADF são idênticas às do teste DF.

O teste de Phillips-Perron é semelhante aos dois testes anteriores, no entanto contém uma correção automática, permitindo aos erros serem autocorrelacionados. As hipóteses referentes ao teste PP são idênticas às do teste ADF.

Por último, o teste de KPSS, chamado de teste de estacionariedade, foi desenvolvido com o objetivo de ser um contraposto aos testes de raiz unitária usuais. Este teste considera as seguintes hipóteses:

$$H_0: \rho < 1 \text{ (a série é estacionária)} \text{ versus } H_1: \rho = 1 \text{ (a série não é estacionária)}$$

Seja $s_t = \sum_{i=1}^t \varepsilon_i$ e $\hat{\sigma}^2$ um estimador para a variância dos erros, a estatística de teste é dada por:

$$LM = \sum_{t=1}^T \frac{s_t^2}{n^2 \hat{\sigma}^2} \quad (2.9)$$

Neste teste rejeita-se H_0 se a estatística de teste $LM_{KPSS} >$ valores críticos usuais.

O teste KPSS é geralmente usado como complemento dos testes apresentados anteriormente, já que apresenta uma diferença significativa nas hipóteses testadas. É também frequentemente utilizado como critério de desempate na discordância entre os testes ADF e PP.

2.3. Modelos Univariados

Os modelos univariados de séries temporais utilizam unicamente os valores passados das mesmas para modelizar e prever observações futuras. Como foi referido no capítulo anterior, um desses modelos é o modelo ARMA, usado para modelizar séries estacionárias. Para séries não-estacionárias, aplica-se o modelo ARIMA, onde o I é referente ao processo de integração de uma série não estacionária, com o auxílio de diferenças sucessivas ou diferenças logaritmizadas.

Os modelos da família ARMA/ARIMA assumem variância dos erros constante ao longo do tempo (homocedasticidade). Em contrapartida, os modelos da família ARCH/GARCH conseguem captar a heterocedasticidade condicional nos erros do modelo, captando a volatilidade das séries temporais.

Como já foi referido, existe uma extensão destes modelos, o modelo ARIMA-GARCH, modelo este que incorpora o modelo da família ARMA/ARIMA com o modelo GARCH, conseguindo assim captar a volatilidade das séries temporais (heterocedasticidade). Neste tipo de modelos a média é modelizada através do modelo ARIMA e a variância com o modelo GARCH. As previsões obtidas por ambas as equações irão ser somadas para criar a previsão final deste modelo, sendo este um procedimento não muito frequente no estudo de séries temporais financeiras com os modelos híbridos ARIMA-GARCH.

2.3.1. Modelos Autoregressivos - AR(p)

Os modelos autoregressivos são modelos nos quais o valor da variável dependente Y_t depende apenas do valor dessa mesma variável em períodos passados, somado com um termo de erro. Com isto, o modelo autoregressivo de ordem p - AR(p) - é escrito da seguinte forma:

$$Y_t = a_0 + \sum_{i=1}^p a_i Y_{t-i} + \varepsilon_t, \text{ com } \varepsilon_t \sim WN(0, \sigma^2) \quad (2.10)$$

onde $a_0, a_1, \dots, a_p$ são os coeficientes do modelo, p é a ordem de defasamento, ε_t é um processo de ruído branco.

Seja L o operador de defasamento, representado por $L(Y_t) = Y_{t-1}$. O modelo anterior pode ser reescrito em:

$$\phi(L)Y_t = a_0 + \varepsilon_t \quad (2.11)$$

onde

$$\phi(L) = 1 - \sum_{i=1}^p a_i L^i \quad (2.12)$$

Um processo autoregressivo de ordem p é estacionário caso todas as raízes $z = \frac{1}{\alpha_i}$ do polinómio

$$\phi(z) = 1 - \sum_{i=1}^p a_i z^i \quad (2.13)$$

estão situadas no exterior do círculo unitário, isto é, se $|\alpha_i| < 1$.

2.3.2. Modelos de Média Móvel - MA(q)

Os modelos de média móvel são feitos através de uma combinação linear de processos de ruído branco, de modo que a variável dependente Y_t seja influenciada pelos valores atuais e passados de um termo de distribuição de ruído branco.

Seja ε_t um processo de ruído branco. O processo MA(q) pode ser representado por:

$$Y_t = \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (2.14)$$

Ao utilizar o operador de desfaseamento, o processo modifica-se novamente:

$$Y_t = \sum_{i=1}^q \theta_i L^i \varepsilon_t = \theta_q(L) \varepsilon_t \quad (2.15)$$

onde $\theta_q(L) = 1 + \sum_{i=1}^q \theta_i L^i$ e θ_i são constantes reais. Um processo MA(q) é *fracamente estacionário* para a totalidade dos valores de θ_q .

2.3.3. Modelos Autoregressivos de Médias Móveis - ARMA(p, q)

Ao combinar o modelo autoregressivo de ordem p , AR(p), com o modelo de média móvel de ordem q , MA(q), obtém-se o modelo autoregressivo de médias móveis, ARMA(p, q).

Este modelo afirma que o valor atual de uma variável Y_t depende linearmente dos seus valores passados (AR), somado a uma combinação de valores presentes e históricos de um termo de erro de ruído branco (MA). Sendo assim, o modelo ARMA(p, q) define-se pela seguinte equação:

$$Y_t = a_0 + \sum_{i=1}^p a_i Y_{t-i} + \sum_{k=1}^q \theta_k \varepsilon_{t-k} + \varepsilon_t \quad (2.16)$$

Este modelo é muito eficaz no que toca à previsão de valores de séries temporais, no entanto tem certas limitações. Uma dessas limitações é o modelo assumir que todas as séries temporais são estacionárias, o que não é verídico, já que a maioria das séries temporais são não-estacionárias.

2.3.4. Modelos Autoregressivos Integrados de Médias Móveis - ARIMA

(p, d, q)

Os modelos do grupo ARMA assumem que todas as séries temporais são estacionárias, algo que pode não ser verificado. Foi então definido o modelo ARIMA(p, d, q), onde o d representa o número de vezes que a série temporal teve de ser diferenciada até atingir estacionariedade, o p representa a ordem da AR e o q representa a ordem da componente MA.

É também importante referir que os modelos univariados previamente apresentados estão inseridos dentro do modelo ARIMA(p, d, q), isto é:

- ARIMA($p, 0, q$) = ARMA(p, q)
- ARIMA($p, 0, 0$) = AR(p)
- ARIMA($0, 0, q$) = MA(q)

2.3.5. A Metodologia de Box-Jenkins

A metodologia de Box-Jenkins foi desenvolvida com o objetivo de estimar modelos do tipo ARMA/ARIMA de uma forma sistemática. Esta metodologia segue três passos:

- Passo 1 - Identificação

Este passo consiste na determinação da ordem do modelo necessária para capturar as características dos dados. Para este passo são utilizadas as funções de autocorrelação (ACF) e autocorrelação parcial (PACF) como auxílio gráfico e os critérios de informação, como o AIC (*Akaike Information Criterion*) e o BIC (*Bayesian Information Criterion*), com o objetivo de escolher o número de parâmetros que minimizam o valor dos critérios de informação. No entanto, a adição de um termo extra só diminui o valor do critério de informação se o decréscimo na soma dos resíduos ao quadrado for mais acentuado que o acréscimo do valor do termo de penalidade. As equações para o AIC e BIC são dadas por, respectivamente,

$$AIC = \ln(\hat{\sigma}^2) + \frac{2k}{T} \quad (2.17)$$

$$BIC = \ln(\hat{\sigma}^2) + \frac{k}{T} \ln(T) \quad (2.18)$$

onde $\hat{\sigma}^2$ é a variância residual, que é equivalente à divisão da soma dos resíduos ao quadrado pelo número de observações T , e $k = p + q + 1$, que é o número total de parâmetros estimados.

- Passo 2 - Estimação

Neste passo são estimados os parâmetros do modelo previamente escolhido. Esta estimação pode ser feita através do Método dos Mínimos Quadrados ou de Máxima Verosimilhança. A escolha do tipo de método vai depender das características do modelo.

- Passo 3 - Diagnóstico

Neste passo deve-se verificar se o modelo estimado é adequado, sendo necessária uma análise aos resíduos.

Para que o modelo seja validado, ele tem que verificar os seguintes pressupostos:

- (1) $E(\varepsilon_t) = 0$: erros têm de ter valor médio nulo;
- (2) $var(\varepsilon_t) = \sigma^2 < \infty$: variância dos erros constante e finita (homocedasticidade). Caso contrário, os erros do modelo são heterocedásticos;
- (3) $cov(\varepsilon_i, \varepsilon_j) = 0$, $i \neq j$: não existe qualquer correlação entre os erros ao longo do tempo, sendo eles linearmente independentes;
- (4) $\varepsilon_t \sim N(0, \sigma^2)$: os erros têm de ser normalmente distribuídos.

2.4. Modelos ARCH/GARCH

Como já foi referido anteriormente, os modelos univariados lineares apresentados até agora (ARMA/ARIMA) assumem que a variância dos erros é constante ao longo do tempo,

algo pouco provável quando se trata de séries temporais financeiras. Outros problemas que podem surgir com modelos desta família é a incapacidade de explicar certas características financeiras importantes, como a leptocurtose, os *clusters* de volatilidade e o efeito de alavanca.

Com o intuito de tentar solucionar alguns desses problemas, foi criado o modelo ARCH(q) (*Autoregressive Conditional Heteroskedasticity*), desenvolvido por Engle em 1982. Posteriormente, uma extensão do modelo ARCH foi definida, o chamado modelo GARCH(p, q) (*Generalized Autoregressive Conditional Heteroskedasticity*).

2.4.1. O modelo GARCH

Introduzido por Bollerslev em 1986, este modelo permite à variância condicional ser dependente dos seus próprios desfasamentos.

O modelo GARCH(p, q) define-se por duas equações: a equação da média

$$y_t = \phi_1 + \phi_2 y_{t-1} + \dots + \phi_k y_{t-k} + \varepsilon_t, \varepsilon_t \sim N(0, \sigma_t^2) \quad (2.19)$$

e a equação da variância

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_q \varepsilon_{t-q}^2 + \beta_1 \sigma_{t-1}^2 + \dots + \beta_p \sigma_{t-p}^2 \quad (2.20)$$

onde σ_t^2 é a variância condicionada, α_0 é a constante, ε_{t-q}^2 é a volatilidade do período anterior e σ_{t-p}^2 é a variância do período anterior. Para a equação da variância, os coeficientes devem ser não-negativos.

É importante referir que um modelo do tipo GARCH($0, q$) é equivalente a um modelo ARCH(q).

No que segue, e sem perda de generalidade, vai ser apresentado o modelo GARCH($1,1$), considerado o modelo *baseline* para os retornos de séries financeiras:

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta \sigma_{t-1}^2 \quad (2.21)$$

onde σ_t^2 é a variância condicional, α_0 é a constante, ε_{t-1}^2 é a volatilidade do período anterior e σ_{t-1}^2 é a variância do período anterior.

No modelo GARCH($1,1$), a variância condicional altera-se, mas a variância não condicional dos erros (u_t) é constante e é dada por

$$var(u_t) = \frac{\alpha_0}{1 - (\alpha_1 + \beta)} \quad (2.22)$$

desde que $\alpha_1 + \beta < 1$. Caso $\alpha_1 + \beta \geq 1$, então existe não-estacionariedade em variância. Por último, caso $\alpha_1 + \beta = 1$, então o modelo GARCH é integrado (também chamado de IGARCH), o que significa que um choque na variância condicional vai ser importante não só no presente, como também em futuras observações.

Como foi discutido anteriormente, modelos do grupo GARCH não são lineares, logo não é possível estimar utilizando o Método dos Mínimos Quadrados. Para estimar modelos do tipo GARCH é utilizada a técnica de Máxima Verosimilhança (MV). Este método consiste em criar uma função log-verosimilhança e procurar pelos valores dos parâmetros

que maximizam a mesma. Esta técnica consegue estimar parâmetros para modelos não lineares e para modelos lineares.

No entanto, os modelos GARCH têm certas limitações: eles não conseguem captar os efeitos de alavancagem, não permitem *feedback* entre média e variância condicional e as condições não negativas poderão ser infringidas com a estimação do modelo.

Para combater estas limitações, foram desenvolvidas várias versões do modelo GARCH, como o IGARCH ou o EGARCH, com o propósito de ganhar habilidade em modelizar os diferentes efeitos e características das séries temporais financeiras. Estas extensões do modelo GARCH não serão abordadas na presente dissertação.

2.5. Random Walk sem drift

O modelo de Random Walk sem *drift* afirma que uma série realiza um passo aleatório em relação ao último valor observado, sendo que estes passos têm média zero. As previsões realizadas por modelos de Random Walk sem *drift* podem ser representadas por

$$\hat{Y}_t = Y_{t-1} \quad (2.23)$$

na qual $\hat{Y}_t$ representa o valor esperado de uma série no momento t e Y_{t-1} indica o valor da série no período $t - 1$. Isto significa que o histórico de uma série não poderá ser utilizado para prever os seus valores futuros.

2.6. Previsão

A última fase deste processo é a previsão de valores a partir dos modelos escolhidos. A fase de previsão está dividida em duas partes: a parte da previsão de valores futuros de uma série temporal e da comparação destes valores previstos com os valores reais da série temporal.

Numa primeira fase, será avaliada a capacidade de ajustamento dos modelos selecionados para as séries originais e para os retornos. A segunda fase passa por uma previsão *in-sample*, ou seja, é uma previsão dentro do intervalo da amostra. Geralmente as previsões *in-sample* têm uma qualidade bastante elevada, por essa mesma razão.

Numa última fase e se as previsões *in-sample* para as séries em estudo forem performatantes, vai-se avançar com as previsões *out-of-sample*, que são previsões fora do intervalo de observações.

2.6.1. Erro de Previsão

O erro de previsão de uma observação no momento de tempo t é dado pela diferença entre o valor atual observado e o valor previsto em t , isto é

$$e_t = Y_t - \hat{Y}_t \quad (2.24)$$

onde e_t é o erro de previsão observado no momento de tempo t .

Para avaliar o desempenho global de previsões foram selecionadas algumas medidas de erro, nomeadamente o Erro Percentual Absoluto Médio (MAPE), o Erro Absoluto

Médio (MAE) e a Raiz do Erro Quadrático Médio (RMSE). Estas medidas são dadas pelas seguintes fórmulas

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|e_t|}{Y_t} \quad (2.25)$$

$$MAE = \frac{\sum_{t=1}^n |e_t|}{n} \quad (2.26)$$

$$RMSE = \sqrt{\frac{\sum_{t=1}^n e_t^2}{n}} \quad (2.27)$$

Com isto, quanto menores forem os erros de previsão, melhores serão as previsões pelo modelo escolhido. É também importante referir que as previsões ficam cada vez menos eficazes caso se aumente a janela de previsão.

CAPÍTULO 3

Análise Empírica

Neste capítulo serão aplicados os conhecimentos teóricos apresentados anteriormente, com o objetivo de encontrar o modelo econométrico que melhor se ajuste aos dados das séries temporais selecionadas e que minimize o erro de previsão.

Neste sentido, serão analisadas duas séries temporais representantes das taxas de câmbio EUR/CNY e EUR/USD, ambas com valores registados entre janeiro de 2002 e fevereiro de 2022 e frequência mensal, num total de 242 observações.

Todos os valores observados referentes às séries temporais foram retirados da base de dados do Banco Central Europeu.

Os *outputs* neste capítulo, incluindo os gráficos e tabelas, foram obtidos com o auxílio da linguagem de programação *Python* e o *Jupyter Notebook*.

3.1. Análise das Séries Temporais

As duas séries em estudo são as taxas de câmbio EUR/CNY e EUR/USD. Para perceber melhor o comportamento das séries temporais, é importante analisar graficamente as mesmas.



FIGURA 3.1. Representação gráfica da série EUR/CNY

Ao analisar a Figura 3.1 verifica-se que a série temporal EUR/CNY apresenta um padrão não linear, com deslocamentos irregulares e com média e variância não constantes, um forte indício de que a série é não-estacionária. Observa-se um aumento no valor desta série temporal entre 2002 até aproximadamente 2005, o que significa uma desvalorização da moeda CNY em relação à moeda EUR. Em 2008 existe uma quebra acentuada, o que indica uma valorização da moeda chinesa em relação ao Euro, em consequência da crise



FIGURA 3.2. Representação gráfica da série EUR/USD

financeira. Durante a pandemia de 2020 houve um aumento ligeiro neste valor, seguido de mais uma queda, o que significa que o CNY valorizou em relação ao EUR neste intervalo.

Em relação à Figura 3.2, a série temporal EUR/USD também apresenta um padrão não linear, as movimentações são irregulares e a sua média e variância também não são constantes. Mais uma vez, a série em estudo aparenta ser não-estacionária. Entre 2002 e 2008 nota-se um crescimento global desta série, o que indica uma desvalorização do USD em relação ao EUR. Tal como a série EUR/CNY, presente na Figura 3.1, a série EUR/USD apresenta quebras acentuadas a partir de 2008, ou seja, o Dólar Americano valorizou durante este intervalo em relação ao Euro. Após o início da pandemia do COVID-19, é importante referir um crescimento no valor da série temporal, o que significa uma desvalorização do USD em relação ao EUR.

Completa-se a análise visual das séries temporais com as medidas de estatística descritiva que se fazem corresponder a cada uma das variáveis.

Estatísticas Descritivas	EUR/CNY	EUR/USD
Observações	242	242
Média	8.65187	1.23349
Desvio-Padrão	1.15497	0.13486
Mínimo	6.68620	0.87000
Q25	7.75870	1.13058
Q50	8.29020	1.22590
Q75	9.68363	1.32765
Máximo	11.09670	1.57700
Curtose	-1.07372	-0.00373
Simetria	0.43395	0.02967

TABELA 3.1. Estatísticas Descritivas das séries EUR/CNY e EUR/USD

Teste Jarque-Bera	EUR/CNY	EUR/USD
<i>P-value</i>	6.82950×10^{-05}	0.97864

TABELA 3.2. Teste de Normalidade de Jarque-Bera para as séries EUR/CNY e EUR/USD

Ao analisar as estatísticas descritivas da série temporal EUR/CNY, é importante assinalar um coeficiente de curtose inferior a 3, o que significa que a série tem uma distribuição platicúrtica. O coeficiente de simetria desta série é superior a 0, indicando uma distribuição positiva, ou seja, Média $\geq$ Mediana $\geq$ Moda. Em relação ao teste de normalidade Jarque-Bera presente na Tabela 3.2, o *p-value* é inferior a 0.05, logo rejeita-se a hipótese nula e conclui-se que a série EUR/CNY não segue uma distribuição normal.

Em relação às estatísticas descritivas da série EUR/USD, o coeficiente de curtose desta série também é inferior a 3, indicando novamente uma distribuição platicúrtica. O coeficiente de simetria é ligeiramente superior a 0, não existindo uma assimetria significativa. Na Tabela 3.2, o *p-value* do teste de Jarque-Bera para esta série temporal é superior a 0.05, logo não se rejeita a hipótese nula e há confirmação de que a série EUR/USD segue uma distribuição normal.

3.1.1. Estacionariedade

Como foi referido anteriormente, o estudo da estacionariedade é crucial para a análise de séries temporais. Para o estudo da estacionariedade vão ser utilizados três tipos de testes de raiz unitária, para cada uma das séries: o teste ADF, o teste PP e o teste KPSS. Os resultados obtidos para ambas as séries estão presentes nas tabelas seguintes:

Testes - EUR/CNY	<i>P-value</i>
Teste ADF	0.40904
Teste PP	0.546
Teste KPSS	0.01

TABELA 3.3. Testes de Estacionariedade para a série EUR/CNY

Testes - EUR/USD	<i>P-value</i>
Teste ADF	0.03070
Teste PP	0.076
Teste KPSS	0.04545

TABELA 3.4. Testes de Estacionariedade para a série EUR/USD

Ao analisar a Tabela 3.3, tanto no teste ADF como no teste PP, para a série EUR/CNY, não se rejeita a hipótese nula, pois o *p-value* em ambos os testes é superior aos níveis de significância usuais, o que significa que a série é não-estacionaria e tem raiz unitária. O teste KPSS foi também realizado para esta série e está de acordo com os outros dois,

já que rejeita a estacionariedade da série. Conclui-se, então, que a série EUR/CNY é não-estacionária em níveis.

Em relação à Tabela 3.4, o teste ADF apresenta um p -value inferior a 0.05, logo rejeita-se a hipótese nula da série apresentar uma raiz unitária, sendo a série estacionária. No entanto, o teste PP afirma que a série é não-estacionária, pois o seu p -value > 0.05 . Ora, nestes casos é necessário fazer o teste KPSS, que é o teste utilizado para desempatar os testes anteriores, para deixarem de existir incertezas. O teste KPSS conclui que a série é não-estacionária, já que o seu p -value é inferior a 0.05, rejeitando a hipótese nula.

Conclui-se que as séries EUR/CNY e EUR/USD são ambas não-estacionárias, sendo necessário integrar as mesmas pelo menos uma vez, usando as diferenças logarítmicas, na tentativa de estabilização das séries para prosseguir com a análise.

3.2. Análise das Séries - Retornos Logarítmicos

Na tentativa de estacionarizar as duas séries temporais, aplicou-se o processo das diferenças logaritmizadas a ambas as séries, conseguindo as seguintes representações gráficas:




FIGURA 3.3. Representação gráfica dos retornos da série EUR/CNY (RetLogEURCNY)




FIGURA 3.4. Representação gráfica dos retornos da série EUR/USD (RetLogEURUSD)

Ao analisar as Figuras 3.3 e 3.4, observa-se que as séries, nos seus retornos, parecem ter estabilizado, com um valor médio próximo do 0. A volatilidade também aparenta ter diminuído (em ambas as séries), um indicador de que as séries se tornaram estacionárias. No entanto é importante estudar de um modo mais aprofundado os retornos, começando pelas estatísticas descritivas.

Estatísticas Descritivas	RetLogEURCNY	RetLogEURUSD
Observações	241	241
Média	-0.00007	0.00104
Desvio-Padrão	0.02118	0.02170
Mínimo	-0.07590	-0.07566
Q25	-0.01215	-0.01137
Q50	0.00032	0.00125
Q75	0.01279	0.01385
Máximo	0.06548	0.06547
Curtose	0.92094	0.92195
Simetria	-0.10881	-0.15061

TABELA 3.5. Estatísticas Descritivas para os retornos das séries EUR/CNY e EUR/USD

Teste Jarque-Bera	RetLogEURCNY	RetLogEURUSD
<i>P-value</i>	0.01661	0.01328

TABELA 3.6. Teste de Normalidade de Jarque-Bera para os retornos das séries EUR/CNY e EUR/USD

Ao analisar as estatísticas descritivas para a série dos retornos EUR/CNY é importante referir que a conclusão sobre o nível de curtose mantém-se a mesma, já que os retornos continuam a seguir uma distribuição platicúrtica, tal como a série original. Em relação à simetria, a conclusão nos retornos é diferente, pois o seu coeficiente é ligeiramente inferior a 0, logo é ligeiramente enviesada. Em relação ao teste de Jarque-Bera presente na Tabela 3.6, o *p-value* é inferior aos níveis de significância, logo rejeita-se a hipótese nula e conclui-se que a série RetLogEURCNY não apresenta normalidade.

Em relação às estatísticas para os retornos da série EUR/USD, conclui-se que a mesma segue uma distribuição platicúrtica em relação à curtose, já que o coeficiente observado é inferior a 3, e é ligeiramente enviesada, no que toca à simetria. Na Tabela 3.6 está presente o teste de Jarque-Bera para esta série e conclui-se que a série não apresenta normalidade, já que o seu *p-value* é inferior aos níveis de significância, rejeitando a hipótese nula da série RetLogEURUSD apresentar normalidade.

3.2.1. Estacionariedade das séries dos retornos logarítmicos

Foram novamente aplicados os três testes de raiz unitária, o teste ADF, o teste PP e o teste KPSS, para analisar a estacionariedade dos retornos:

Testes - RetLogEURCNY	<i>P-value</i>
Teste ADF	4.22843×10^{-21}
Teste PP	0.000
Teste KPSS	0.1

TABELA 3.7. Testes de Estacionariedade para a série RetLogEURCNY

Testes - RetLogEURUSD	<i>P-value</i>
Teste ADF	1.38687×10^{-20}
Teste PP	0.000
Teste KPSS	0.1

TABELA 3.8. Testes de Estacionariedade para a série RetLogEURUSD

Ao analisar a Tabela 3.7 percebe-se que os testes ADF e PP estão de acordo, ou seja, em ambos os testes rejeita-se para os níveis de significância usuais a hipótese nula da presença de uma raiz unitária na série, concluindo que a série RetLogEURCNY é estacionária. O teste KPSS está simultaneamente de acordo com os outros dois, garantindo a estacionariedade da série RetLogEURCNY.

Em relação aos testes para a série RetLogEURUSD presentes na Tabela 3.8, os testes ADF e PP estão novamente de acordo e rejeitam a hipótese nula da série apresentar uma raiz unitária, logo a série é estacionária. O teste KPSS está mais uma vez de acordo com o teste ADF e PP, já que o seu valor da estatística de teste é inferior aos valores críticos, logo não se rejeita a hipótese nula da série ser estacionária, garantindo a estacionariedade da série RetLogEURUSD.


Como as séries foram diferenciadas apenas uma vez para atingir estacionariedade, conclui-se que ambas as séries são integradas de ordem 1 (I(1)).

3.3. Estimação dos Modelos Univariados


Garantida a estacionariedade em ambas as séries, agora é importante escolher o modelo para continuar o estudo empírico. Para isso, será necessário analisar a representação gráfica da função de autocorrelação (ACF) e função de autocorrelação parcial (PACF), de ambas as séries, para tentar perceber a ordem dos modelos univariados.

Ao analisar as Figuras 3.5 e 3.6 percebe-se que só o primeiro *lag* é significativo, para ambas as funções e séries.

Como foi referido em capítulos anteriores, analisar estas funções não é suficiente para descobrir o modelo ótimo para o conjunto de dados. Para isso, foi utilizada uma função




(A) ACF RetLogEURCNY




(B) PACF RetLogEURCNY

FIGURA 3.5. Funções ACF e PACF para a série RetLogEURCNY



(A) ACF RetLogEURUSD



(B) PACF RetLogEURUSD

FIGURA 3.6. Funções ACF e PACF para a série RetLogEURUSD

em código chamada de *auto.arima*, que retorna o modelo ARMA que minimiza os critérios de informação AIC e BIC, de modo a facilitar e a melhorar a escolha do modelo ideal.

Para as duas séries, o modelo que minimiza estes dois critérios de informação é o modelo MA(1)¹.

É importante assinalar que o *p-value* no coeficiente MA(1) para ambos os modelos é muito próximo do 0, o que significa que o termo de média móvel é estatisticamente significativo. Para validar os modelos é necessário fazer uma análise aos resíduos de cada um dos modelos escolhidos.

3.4. Análise dos Resíduos

Todos os pressupostos dos resíduos têm de ser satisfeitos, caso contrário o modelo não será válido para a previsão das séries em estudo.

O primeiro pressuposto a estudar é se os resíduos de cada modelo apresentam valor médio nulo. Foi novamente necessário analisar as estatísticas descritivas, para observar o valor médio dos resíduos:

¹Os *outputs* dos modelos ótimos para as séries RetLogEURCNY e RetLogEURUSD estão presentes no Anexo A e Anexo B, respetivamente

Série	Valor Médio
RetLogEURCNY	0.00
RetLogEURUSD	0.00

TABELA 3.9. Primeiro Pressuposto dos Resíduos – Valor Médio Nulo

De acordo com a Tabela 3.9, os resíduos em ambos os casos apresentam valor médio muito próximo de zero, logo o primeiro pressuposto dos resíduos está cumprido, para ambas as séries.

O próximo pressuposto a analisar é a independência dos resíduos. Para a validação deste pressuposto foi utilizado o teste de *Ljung-Box*, até à ordem 10. A hipótese nula deste teste é a ausência de correlação dos resíduos dos modelos escolhidos.

Ordem	RetLogEURCNY	RetLogEURUSD		
	Valor	<i>P-value</i>	Valor	<i>P-value</i>
1	0.02098	0.88483	0.05015	0.82280
2	0.06302	0.96898	0.26745	0.87483
3	0.11996	0.98934	0.31042	0.95806
4	4.51343	0.34096	3.50894	0.47652
5	5.13678	0.39942	3.72801	0.58920
6	5.30205	0.50570	4.28864	0.63768
7	8.87490	0.26176	8.71746	0.27358
8	8.93321	0.34796	8.71768	0.36667
9	9.57590	0.38590	9.45345	0.39651
10	9.61722	0.47469	9.45507	0.48953

TABELA 3.10. Resultados do Teste de *Ljung-Box*

Os *p-values* do teste de *Ljung-Box* são todos superiores aos níveis de significância usuais, em ambas as séries, logo não se rejeita a hipótese nula, sendo os resíduos independentes entre si até ao *lag* de ordem 10.

O terceiro pressuposto a ser analisado é o da heterocedasticidade dos resíduos, ou seja, da variância dos resíduos não ser constante ao longo do tempo. Para testar a presença de heterocedasticidade, foi feito o teste ARCH nos resíduos de ambos os modelos. O teste ARCH tem como hipótese nula variância constante (homocedasticidade).

Teste ARCH	Valor	<i>P-value</i>
Resíduos RetLogEURCNY	31.66427	0.00
Resíduos RetLogEURUSD	30.79522	0.00

TABELA 3.11. Resultados do Teste ARCH

Ao analisar a Tabela 3.11, conclui-se que ambos os *p-values* são muito próximos do 0, o que significa que existem efeitos ARCH nos resíduos de ambos os modelos. A existência

de efeitos ARCH significa que a variância nos resíduos não é constante ao longo do tempo, confirmado a heterocedasticidade nos resíduos, em ambos os casos. É importante referir que o pressuposto da normalidade não deve ser verificado, pois a variância dos resíduos é heteroscedástica e o erro teórico dos modelos ARIMA é um processo de ruído branco (não necessariamente Gaussiano).

Confirmada a presença de heterocedasticidade nos resíduos, o próximo passo seria introduzir modelos que não assumissem variância constante ao longo do tempo, como os modelos da família ARCH/GARCH. No entanto, a análise com ambos os modelos MA(1) irá continuar, pois o objetivo da presente dissertação é encontrar o modelo que apresente o menor erro de previsão.

3.5. Previsão

Por fim e para concluir o estudo dos modelos univariados, vai ser abordado o processo de previsão de valores por parte dos modelos selecionados.

A *performance* de cada previsão irá ser comparada entre os modelos selecionados com o auxílio de medidas de erro, como o MAPE, o MAE e o RMSE.

3.5.1. Previsões das séries originais

A previsão de cada série utilizando modelos do tipo ARMA/ARIMA vai ser dividida em três partes: numa primeira parte vai ser avaliado a capacidade de ajustamento do modelo ARIMA(0,1,1) utilizando o conjunto de treino, que é composto pelas primeiras 200 observações, para as séries EUR/CNY e EUR/USD. De seguida é feita a previsão *in-sample*, isto é, é feita uma previsão dentro da janela temporal amostral de cada série, sendo que os valores previstos irão ser comparados com os valores reais presentes no conjunto de teste, através das medidas de erro selecionadas. Por último, é feita uma previsão *out-of-sample*, que é uma previsão fora do intervalo temporal de ambas as séries.

Para recapitular, o modelo ótimo foi um modelo MA(1) para as duas séries em diferenças logaritmizadas ou, por equivalência, o modelo ARIMA(0,1,1) para as séries originais.

Assim sendo, este processo começa com os valores ajustados pelo modelo ARIMA(0,1,1) para as séries EUR/CNY e EUR/USD:

Pela análise das Figuras 3.7 e 3.8, percebe-se que, tanto para a série EUR/CNY como para a série EUR/USD, o ajustamento apresenta bons resultados. No entanto, esta análise não é suficiente, sendo necessária uma análise mais aprofundada, com o auxílios das medidas de erro. A Tabela 3.12 contém os valores para cada uma das medidas de erro, tendo em conta o valor previsto e o valor real observado para ambas as séries.



FIGURA 3.7. Valores ajustados do modelo ARIMA(0,1,1) para o conjunto de treino da série EUR/CNY




FIGURA 3.8. Valores ajustados do modelo ARIMA(0,1,1) para o conjunto de treino da série EUR/USD

Medidas de Erro	Valores ajustados - EUR/CNY	Valores ajustados - EUR/USD
MAE	0.18253	0.02588
MAPE	0.02137	0.02206
RMSE	0.55149	0.06841

TABELA 3.12. Valores das Medidas de Erro para os valores ajustados pelo modelo ARIMA(0,1,1) do conjunto de treino das séries EUR/CNY e EUR/USD

De acordo com a Tabela 3.12, conclui-se que estes modelos têm boa capacidade de aprendizagem, já que os valores observados em cada medida de erro são relativamente pequenos.

3.5.2. Previsões *in-sample* para as séries originais

Confirmada uma boa capacidade de aprendizagem dos modelos ARIMA selecionados, o próximo passo no estudo de previsões utilizando este tipo de modelos passa pela previsão *in-sample*, onde são previstos valores dentro do intervalo de observações. Como forma de comparação entre os valores previstos e os valores reais de cada série, vão ser utilizadas as medidas de erro previamente abordadas².

Foram escolhidos quatro tipos de modelos diferentes para efetuar previsões: o modelo ARIMA(0,1,1), para ambas as séries, onde será feita uma previsão ponto a ponto, isto é, será feita uma previsão apenas de um ponto futuro, sendo que esse ponto será adicionado ao conjunto de treino para fazer previsão do ponto seguinte (*Expanding Window Forecast*³); o modelo híbrido ARIMA(0,1,1)-GARCH(1,1)⁴, para ambas as séries, onde serão somadas as previsões obtidas pelo modelo ARIMA com as previsões do modelo GARCH para os resíduos do modelo ARIMA, considerando, assim, a volatilidade das séries temporais financeiras; o modelo de Random Walk, onde serão simulados pontos futuros sem qualquer relação com observações passadas; por último, será utilizado o algoritmo Prophet, onde as previsões serão automatizadas por esta biblioteca em código.

Todos os valores previstos por estes modelos foram extraídos do *Python* e trabalhados em *Excel*.

A figura seguinte mostra os valores previstos por estes modelos para a série EUR/CNY, incluindo o conjunto de teste, onde estão presentes os valores reais para esta série temporal⁵:

²Os *outputs* dos modelos ARIMA(0,1,1) dos conjuntos de treino para as séries EUR/CNY e EUR/USD estão presentes no Anexo C.

³O modelo ARIMA(0,1,1) tem fraca capacidade de previsão, sendo necessário a utilização deste método para contrariar esse obstáculo

⁴Os *outputs* dos modelos GARCH(1,1) para os resíduos dos modelos ARIMA para as séries EUR/CNY e EUR/USD estão presentes no Anexo D.

⁵Os valores previstos por cada modelo para a série EUR/CNY estão presentes no Anexo E.




FIGURA 3.9. Previsão de valores da série EUR/CNY com vários modelos econométricos

Ao analisar a Figura 3.9 observa-se que, em termos visuais, o Prophet é o modelo que apresenta a pior capacidade de previsão, comparativamente aos restantes modelos. A razão pela qual isto acontece é devido à própria natureza do Prophet, já que a sua especialidade é trabalhar com séries que apresentam sazonalidade, algo que não acontece com as séries em estudo na presente dissertação. Pela figura, percebe-se que os modelos que apresentam melhor capacidade de previsão são o modelo recursivo ARIMA(0,1,1) e o modelo híbrido ARIMA(0,1,1)-GARCH(1,1).

No entanto, a análise visual do comportamento de cada previsão não é suficiente, sendo necessário um estudo mais aprofundado. Para isso, serão utilizadas as medidas de avaliação da *performance* de previsão e irá ser feita uma comparação entre os modelos, para descobrir qual dos modelos tem o menor erro de previsão. A tabela seguinte contém os valores de erro para cada um dos modelos estudados:

EUR/CNY	ARIMA(0,1,1)	ARIMA(0,1,1)-GARCH(1,1)	Random Walk	Prophet
MAE	0.23462	<u>0.09943</u>	0.24543	0.25332
MAPE	0.03060	<u>0.01284</u>	0.03239	0.03256
RMSE	0.30891	<u>0.11220</u>	0.30597	0.29114

TABELA 3.13. Valores das medidas de erros das previsões para a série EUR/CNY

Ao analisar a Tabela 3.13 verifica-se que o modelo ARIMA(0,1,1)-GARCH(1,1) apresenta o menor valor para todas as medidas de erro, logo é o modelo que tem melhor capacidade de previsão para a série EUR/CNY, dentro dos modelos escolhidos.

A figura seguinte mostra os valores previstos por estes modelos para a série EUR/USD, incluindo o conjunto de teste, onde estão presentes os valores reais para esta série temporal⁶:




FIGURA 3.10. Previsão de valores da série EUR/USD com vários modelos econométricos

Ao analisar a Figura 3.10 percebe-se que, mais uma vez, o Prophet não apresenta uma previsão muito eficaz desta série temporal. Visualmente, os modelos ARIMA(0,1,1) e ARIMA(0,1,1)-GARCH(1,1) apresentam a melhor previsão entre os modelos escolhidos, no entanto é necessário analisar os valores das medidas de erro para cada um dos modelos, que estão presentes na Tabela 3.14:

EUR/USD	ARIMA(0,1,1)	ARIMA(0,1,1)-GARCH(1,1)	Random Walk	Prophet
MAE	0.04340	<u>0.01138</u>	0.05792	0.10663
MAPE	0.03775	<u>0.00991</u>	0.05090	0.09151
RMSE	0.05384	<u>0.01429</u>	0.06772	0.12374

TABELA 3.14. Valores das medidas de erros das previsões para a série EUR/USD

Ao analisar a Tabela 3.14 constata-se que, tal como nos valores previstos para a série EUR/CNY, o modelo híbrido ARIMA(0,1,1)-GARCH(1,1) apresenta o menor valor em todas as medidas de erro, sendo assim o modelo com melhor capacidade de previsão para a série EUR/USD, dos modelos selecionados para análise.

Chegou-se à conclusão que o modelo híbrido ARIMA(0,1,1)-GARCH(1,1) é o que apresenta melhor capacidade de previsão *in-sample* para ambas as séries originais, já que,

⁶Os valores previstos por cada modelo para a série EUR/USD estão presentes no Anexo F.

em ambos os casos, apresenta o menor erro de previsão comparativamente aos restantes modelos estudados, de acordo com as medidas de erro utilizadas. Conclui-se também que os valores das medidas de erro para a série EUR/USD são inferiores aos valores das medidas de erro para a série EUR/CNY, indicando uma menor volatilidade na série EUR/USD.

É importante sublinhar o desempenho das previsões obtidas através do modelo de passeio aleatório, que foi bastante semelhante aos desempenhos dos restantes modelos. Um resultado interessante, sabendo que as previsões do modelo de Random Walk são independentes entre si, enquanto as previsões obtidas pelos restantes modelos têm em conta o histórico das séries temporais.

3.5.3. Previsões *out-of-sample* para as séries originais

Feitas as previsões *in-sample*, passamos agora para as previsões *out-of-sample* das séries EUR/CNY e EUR/USD. A previsão *out-of-sample* consiste na previsão de valores fora do intervalo de observações. Neste caso e para ambas as séries, vai ser apenas prevista a próxima observação, referente ao mês seguinte (mês de março de 2022). Após a realização destas previsões, irá ser calculado o erro de previsão para cada modelo, na tentativa de descobrir qual dos modelos selecionados apresenta melhor capacidade de previsão *out-of-sample*.

Para o mês de março de 2022, o valor observado para a série temporal EUR/CNY foi 6.9916.

A tabela seguinte apresenta os valores previstos *out-of-sample* por cada modelo para a série EUR/CNY, incluindo o erro de previsão para cada um dos valores previstos:

EUR/CNY	ARIMA(0,1,1)	ARIMA(0,1,1)-GARCH(1,1)	Random Walk	Prophet
Valor Previsto	7.195701	7.210686	7.206962	7.76119
Erro de Previsão	<u>0.204101</u>	0.21909	0.215362	0.769587

TABELA 3.15. *Performance* das previsões *out-of-sample* para a série EUR/CNY

Ao analisar a Tabela 3.15 percebe-se que as previsões *out-of-sample* não são as melhores, já que os erros de previsão observados para todos os modelos são altos. No entanto, estes valores altos devem-se a uma quebra grande do valor real desta série temporal, entre o mês de fevereiro e o mês de março, em que o valor real passa de 7.1957 para 6.9916. Esta quebra poderá estar relacionada com os problemas mundiais atuais, mais precisamente da invasão da Ucrânia pelas tropas russas, criando instabilidade económica mundial e influenciando o valor das taxas cambiais.

O modelo que apresentou o menor erro de previsão foi o modelo ARIMA(0,1,1). Dos restantes modelos, o Prophet foi o que apresentou a pior previsão, já que apresenta um erro de previsão bastante mais elevado comparativamente aos restantes modelos.

Feita a previsão *out-of-sample* para a série EUR/CNY, passamos agora para a previsão *out-of-sample* para a outra série original, a série EUR/USD.

Para o mês de março de 2022, o valor observado para a série temporal EUR/USD foi 1.1019.

A tabela seguinte apresenta os valores previstos *out-of-sample* por cada modelo para a série EUR/USD, incluindo o erro de previsão para cada um dos valores previstos:

EUR/USD	ARIMA(0,1,1)	ARIMA(0,1,1)-GARCH(1,1)	Random Walk	Prophet
Valor Previsto	1.134767	1.135208	1.145462	1.1433
Erro de Previsão	<u>0.032867</u>	0.033308	0.043562	0.041414

TABELA 3.16. *Performance* das previsões *out-of-sample* para a série EUR/USD

Ao analisar a Tabela 3.16 percebe-se que, mais uma vez, as previsões *out-of-sample* não são as melhores, já que apresentam um erro de previsão moderado. O valor observado para o mês de fevereiro de 2022 para esta série foi 1.1342, ocorrendo novamente uma quebra para o mês de março de 2022, onde o valor observado foi 1.1019. Mais uma vez, esta quebra poderá estar relacionada com a invasão do território ucraniano por tropas russas, já que estes meses coincidem com o início do conflito, criando uma instabilidade económica a nível mundial e afetando os valores da taxa de câmbio EUR/USD.

Dos modelos selecionados, o que apresentou menor erro de previsão foi o modelo ARIMA(0,1,1), já que a previsão *out-of-sample* é a mais próxima do valor real.

Conclui-se que, devido à instabilidade económica criada pelos eventos atuais, as previsões *out-of-sample* não foram as melhores, tanto para a série EUR/CNY como para a série EUR/USD, já que apresentaram um erro de previsão relativamente elevado. Para ambas as séries temporais, o modelo que apresentou o menor erro de previsão foi o modelo ARIMA(0,1,1), visto que as previsões obtidas por este modelo foram as mais próximas do valor real para cada série, dos modelos selecionados para análise.

3.5.4. Previsões das séries em diferenças logaritmizadas

Nas subsecções anteriores as previsões foram realizadas a partir das séries originais das taxas de câmbio, no entanto seria interessante também estudar e prever os retornos. Os valores ajustados pelo modelo MA(1) para as séries RetLogEURCNY e RetLogEURUSD estão presentes nas Figuras 3.11 e 3.12, respetivamente.

Através da observação das Figuras 3.11 e 3.12, percebe-se que estes modelos têm uma boa capacidade de aprendizagem, já que conseguem captar relativamente bem o comportamento das séries em estudo, contudo não conseguem captar os períodos de maior oscilação, tanto na série RetLogEURCNY como na série RetLogEURUSD.

A Tabela 3.17 contém os valores das medidas de erro para os valores ajustados das séries RetLogEURCNY e RetLogEURUSD.




FIGURA 3.11. Valores ajustados do modelo MA(1) para o conjunto de treino da série RetLogEURCNY




FIGURA 3.12. Valores ajustados do modelo MA(1) para o conjunto de treino da série RetLogEURUSD

Medidas	Valores ajustados - RetLogEURCNY	Valores ajustados - RetLogEURUSD
MAE	0.01646	0.01714
MAPE	1.70916	—
RMSE	0.02151	0.02199

TABELA 3.17. Valores das Medidas de Erro para os valores ajustados do conjunto de treino das séries RetLogEURCNY e RetLogEURUSD

Ao fazer uma análise à Tabela 3.17⁷ observa-se um desempenho mediano na capacidade de aprendizagem, já que os valores das medidas de erro para as previsões são relativamente elevados para retornos. É também importante referir que o modelo MA(1) tem uma melhor capacidade de aprendizagem para os retornos da série EUR/CNY do que para os retornos da série EUR/USD, o que não acontece com as séries originais, já que o modelo

⁷Não foi possível calcular o MAPE para os valores ajustados da série RetLogEURUSD (divisor não pode ser igual a 0)

ARIMA(0,1,1) tem melhor capacidade de aprendizagem para a série EUR/USD do que para a série EUR/CNY.

Mesmo com um desempenho mediano na capacidade de aprendizagem, vamos avançar com as previsões *in-sample* para estas séries, com o objetivo de encontrar o modelo que apresente menor erro de previsão, dos modelos selecionados.

3.5.5. Previsões *in-sample* para as séries em diferenças logaritmizadas

Para prever as próximas observações das séries em diferenças logaritmizadas irão ser utilizados os mesmos modelos que foram usados para prever as séries originais, porém o modelo ARIMA passa para um modelo ARIMA(0,0,1) (ou MA(1))⁸, visto que estamos a tratar de séries em diferenças logaritmizadas⁹.

A figura seguinte mostra os valores previstos pelos modelos selecionados para a série RetLogEURCNY, incluindo o conjunto de teste, onde estão presentes os valores reais para esta série temporal¹⁰:




FIGURA 3.13. Previsão de valores da série RetLogEURCNY com vários modelos econométricos

Ao fazer uma análise à Figura 3.13 percebe-se que os modelos ARIMA(0,0,1), ARIMA(0,0,1)-GARCH(1,1) e Prophet apresentam as melhores previsões, no entanto não conseguem captar os momentos de maior oscilação desta série temporal. Para estudar melhor estas

⁸Os *outputs* dos modelos MA(1) dos conjuntos de treino para as séries RetLogEURCNY e RetLogEURUSD estão presentes no Anexo G.

⁹Os *outputs* dos modelos GARCH(1,1) para os resíduos dos modelos MA(1) para as séries RetLogEURCNY e RetLogEURUSD estão presentes no Anexo H.

¹⁰Os valores previstos por cada modelo para a série RetLogEURCNY estão presentes no Anexo I

previsões, é novamente necessário utilizar as medidas de erro, com o intuito de descobrir qual o modelo (dos escolhidos) é o melhor para fazer previsões da série temporal em análise.

A tabela seguinte mostra os valores das medidas de erro para as previsões da série RetLogEURCNY:

RetLogEURCNY	MA(1)	MA(1)-GARCH(1,1)	Random Walk	Prophet
MAE	0.01084	0.01073	0.02099	<u>0.00918</u>
MAPE	1.30004	<u>1.12980</u>	4.33530	1.28654
RMSE	0.01291	0.01271	0.02493	<u>0.01165</u>

TABELA 3.18. Valores das medidas de erro das previsões para a série RetLogEURCNY

Ao fazer uma análise à Tabela 3.18 observa-se que o Prophet apresenta as melhores previsões para as medidas de erro MAE e RMSE, já que o valor destas medidas é inferior nos valores previstos pelo Prophet do que nos restantes modelos. No entanto, para a medida de erro MAPE, o modelo que apresenta o menor valor para esta medida é o modelo MA(1)-GARCH(1,1). Neste caso, como Prophet apresenta o menor valor nas medidas de erro MAE e RMSE, conclui-se que é o modelo que apresenta a melhor previsão *in-sample*, dos modelos seleccionados para análise.

A figura seguinte mostra os valores previstos pelos modelos escolhidos para a série RetLogEURUSD, incluindo o conjunto de teste, onde estão os valores reais para a série temporal¹¹:




FIGURA 3.14. Previsão de valores da série RetLogEURUSD com vários modelos econométricos

¹¹Os valores previstos por cada modelo para a série RetLogEURUSD estão presentes no Anexo J

Ao analisar a Figura 3.14, os modelos que visualmente conseguem obter as melhores previsões são os modelos ARIMA(0,0,1), ARIMA(0,0,1)-GARCH(1,1) e Prophet, no entanto estes modelos não conseguem captar os momentos de maior volatilidade.

A tabela seguinte mostra os valores das medidas de erro selecionadas para as previsões da série RetLogEURUSD:

RetLogEURUSD	MA(1)	MA(1)-GARCH(1,1)	Random Walk	Prophet
MAE	0.01117	0.01016	0.01217	<u>0.01010</u>
MAPE	<u>1.32352</u>	4.50315	7.45654	6.18896
RMSE	0.01312	<u>0.01262</u>	0.01529	0.01351

TABELA 3.19. Valores das medidas de erro das previsões para a série RetLogEURUSD

Ao analisar a Tabela 3.19, verifica-se que o Prophet é o que apresenta o valor mais baixo para a medida MAE, em relação à medida MAPE o valor mais baixo pertence ao modelo MA(1) e, por último, o modelo que apresenta o valor mais baixo para a medida RMSE é o modelo MA(1)-GARCH(1,1). Conclui-se que o modelo MA(1) é o modelo que apresenta melhor previsão *in-sample* para a série RetLogEURUSD, já que apresenta um MAPE muito mais baixo que os restantes modelos e apresenta apenas um RMSE e MAE ligeiramente superior aos restantes modelos.

3.5.6. Previsões *out-of-sample* para as séries em diferenças logaritmizadas

Para completar este estudo, foram efetuadas as previsões *out-of-sample* para os retornos. Mais uma vez, irá ser prevista a próxima observação para cada série temporal, com o objetivo de encontrar o modelo que apresenta menor erro de previsão.

Para o mês de março de 2022, o valor observado para a série temporal RetLogEURCNY foi -0.02877.

A tabela seguinte apresenta os valores previstos *out-of-sample* por cada modelo para a série RetLogEURCNY, incluindo o erro de previsão para cada um dos valores previstos:

RetLogEURCNY	MA(1)	MA(1)-GARCH(1,1)	Random Walk	Prophet
Valor Previsto	-0.000051	0.000116	0.002851	-0.002013
Erro de Previsão	0.02872	0.02889	0.03163	<u>0.02676</u>

TABELA 3.20. *Performance* da previsão *out-of-sample* para a série RetLogEURCNY

Ao analisar a Tabela 3.20 observa-se que os erros de previsão são bastante elevados para retornos. Isto acontece devido à quebra do valor observado para a série EUR/CNY, afetando também os retornos. A quebra deste valor é devido a fatores externos e é algo que estes modelos não conseguem prever, o que leva a erros de previsão altos. Dos modelos analisados, o que apresenta o menor erro de previsão *out-of-sample* é o Prophet.

Para o mês de março de 2022, o valor observado para a série temporal RetLogEURUSD foi -0.02889.

A tabela seguinte apresenta os valores previstos *out-of-sample* por cada modelo para a série RetLogEURUSD, incluindo o erro de previsão para cada um dos valores previstos:

RetLogEURUSD	MA(1)	MA(1)-GARCH(1,1)	Random Walk	Prophet
Valor Previsto	0.001275	0.0015	0.004837	-0.003242
Erro de Previsão	0.03017	0.03039	0.03373	<u>0.02565</u>

TABELA 3.21. *Performance* da previsão *out-of-sample* para a série RetLogEURUSD

Ao analisar a Tabela 3.21 constata-se que, mais uma vez, as previsões *out-of-sample* não são as melhores, pois os erros de previsão são bastante elevados para retornos. Novamente, isto deve-se à instabilidade económica criada pelos eventos atuais, afetando negativamente as nossas previsões, já que estes modelos não conseguem prever este tipo de quebras. O Prophet é mais uma vez o modelo que apresenta o menor erro de previsão, neste caso para a série RetLogEURUSD.

Ao analisar estes resultados, chega-se à conclusão que ambos os retornos caíram sensivelmente da mesma forma, já que o valor real observado da série RetLogEURUSD para o mês de março de 2022 foi -0.02889 e o valor real observado da série RetLogEURUSD para a mesma observação foi -0.02889. Isto significa que a moeda Euro depreciou em relação ao Renminbi Chinês e ao Dólar Americano sensivelmente da mesma forma. Esta quebra poderá estar relacionada com os eventos atuais presenciados na Ucrânia, que coincidem com as datas de ambas as observações, criando esta queda nas séries temporais.

Ao fazer as previsões *out-of-sample* com os modelos selecionados, conclui-se que os mesmos não conseguem captar esta queda nos retornos. No entanto, dos modelos selecionados para o estudo, o modelo que apresentou menor erro de previsão foi o Prophet, tanto para a série RetLogEURUSD como para a série RetLogEURUSD.

Conclusões

A importância das taxas de câmbio nas economias nacionais e mundiais tem crescido exponencialmente, muito por culpa da globalização presenciada nas últimas décadas, já que a maioria dos países têm relações internacionais com outros países.

O objetivo da presente dissertação foi tentar analisar e prever séries temporais financeiras, neste caso as taxas de câmbio EUR/CNY e EUR/USD, ambas em frequência mensal, num total de 242 observações para cada.

Para executar previsões de séries temporais foram utilizados quatro modelos econométricos: o modelo ARIMA, o modelo híbrido ARIMA-GARCH, o modelo de Random Walk e o algoritmo Prophet.

Numa primeira fase foram analisadas ambas as séries originais (EUR/CNY e EUR/USD), através da observação gráfica e das estatísticas descritivas de cada série temporal. As séries EUR/CNY e EUR/USD aparentavam ser não-estacionárias, sendo que foram realizados os testes de raiz unitária e concluiu-se que ambas as séries eram, efetivamente, não-estacionárias. Na tentativa de estabilização de ambas as séries recorreu-se às diferenças logaritmizadas para ambos os casos, criando as séries RetLogEURCNY e RetLogEURUSD.

Os retornos foram analisados graficamente, recorreu-se à análise das estatísticas descritivas dos mesmos e foram novamente realizados os testes de raiz unitária. Concluiu-se que as séries RetLogEURCNY e RetLogEURUSD eram integradas de ordem 1 ($I(1)$), atingindo estacionariedade depois de terem sido diferenciadas uma vez.

De seguida foi procurado o modelo ARIMA que minimizava os critérios de informação AIC e BIC. Observou-se que o modelo ARIMA(0,1,1) era o modelo ideal para as séries originais (EUR/CNY e EUR/USD), equivalente a um modelo MA(1) para os retornos, em ambos os casos.

Para os modelos serem válidos para previsão, foi necessário fazer uma análise aos resíduos de cada um dos modelos. Verificou-se que os resíduos de ambos os modelos eram heteroscedásticos, o que significa que a variância dos mesmos não era constante ao longo do tempo. Como o objetivo do presente trabalho era encontrar o modelo que previa com menor erro, continuou-se o estudo com os modelos em causa.

Antes de realizar as previsões *in-sample* com os modelos selecionados, foi feita uma avaliação na capacidade de ajustamento do modelo ARIMA(0,1,1), onde se separou a amostra em conjunto de treino e conjunto de teste, para as séries EUR/CNY e EUR/USD. Feito o ajustamento, observou-se que ambos os modelos para as séries originais tinham

boa capacidade de aprendizagem, já que apresentaram valores baixos nas medidas de erro utilizadas.

Seguiu-se a previsão *in-sample* das séries EUR/CNY e EUR/USD e concluiu-se que os modelos ARIMA(0,1,1)-GARCH(1,1) apresentavam o menor valor para todas as medidas de erro utilizadas, para ambas as séries originais, dentro dos modelos selecionados. As previsões *in-sample* para as séries originais apresentaram resultados muito bons, portanto prosseguiu-se com as previsões, neste caso com as previsões *out-of-sample*, para as séries EUR/CNY e EUR/USD.

No que toca à previsão *out-of-sample*, o modelo que apresentou menor erro de previsão para as séries EUR/CNY e EUR/USD foi o modelo ARIMA(0,1,1). As previsões *out-of-sample* não foram as melhores, devido a uma quebra no valor real observado para ambas as séries, derivado da instabilidade política criada pelos eventos atuais, afetando o erro de previsão de forma negativa.

Como também seria interessante estudar e prever os retornos, foram realizados ajustamentos do modelo MA(1), realizaram-se as previsões *in-sample* e também as previsões *out-of-sample*, para as séries RetLogEURCNY e RetLogEURUSD.

Através da análise dos ajustamentos, para as séries RetLogEURCNY e RetLogEURUSD, percebeu-se que o modelo MA(1), para ambos os casos, conseguia captar relativamente bem o comportamento dos retornos mas não conseguia captar os períodos de maior oscilação.

Foram novamente realizadas as previsões *in-sample*, neste caso para os retornos, e concluiu-se que o Prophet apresentou a melhor *performance* para a série RetLogEURCNY. No que toca à previsão *in-sample* para a série RetLogEURUSD, o modelo que apresentou a melhor previsão *in-sample* foi o modelo MA(1).

Feita a previsão *in-sample*, seguiu-se com a previsão *out-of-sample* para os retornos. Verificou-se que, para as séries RetLogEURCNY e RetLogEURUSD, o modelo que apresentou menor erro de previsão foi o Prophet. Mais uma vez, as previsões *out-of-sample* não foram as melhores, muito devido às quebras que ocorreram nas taxas de câmbio, o que influenciou negativamente as nossas previsões dos retornos.

Referências Bibliográficas

- Abreu, R. J., Souza, R. M., & Oliveira, J. G. (2019). Applying singular spectrum analysis and ARIMA-GARCH for forecasting EUR/USD exchange rate. *RAM. Revista De Administração Mackenzie*, 20(4). <https://doi.org/10.1590/1678-6971/eramf190146>
- Amadeo, K. (2022, May 26). How a 1944 agreement created a New International Monetary System. *The Balance*. <https://www.thebalancemoney.com/bretton-woods-system-and-1944-agreement-3306133>
- Brooks, C. (2019). *Introductory Econometrics for Finance* (4th ed.). Cambridge University Press. <https://doi.org/10.1017/9781108524872>
- DailyFX. (2018, September 12). CNH vs CNY: Differences Between the Two Yuan. *Nasdaq*. <https://www.nasdaq.com/articles/cnh-vs-cny-differences-between-two-yuan-2018-09-12>
- European Central Bank (2007). *How the Euro Became Our Money: a Short History of the Euro Banknotes and Coins*. European Central Bank. https://www.ecb.europa.eu/pub/pdf/other/euro_became_our_moneyen.pdf
- Facebook. (2017). Facebook Prophet documentation. <https://facebook.github.io/prophet/>
- Farhan, A. K., & Fakhir, M. R. (2019). Forecasting the exchange rates of the Iraqi dinar against the US dollar using the Time Series model (ARIMA). *International Journal of Engineering and Management Research*, 09(06), 50–55. <https://doi.org/10.31033/ijemr.9.6.8>
- Kolari, J. W., & Sanz, I. P. (2022). Forecasting bank capital ratios using the Prophet model by Facebook. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4141575>
- Krugman, P. R., Obstfeld, M., & Melitz, M. J. (2012). *International Economics: Theory & Policy* (9th ed.). Pearson
- Maganlal, M. H. (2019). *Taxas de câmbio: modelação ARMA-GARCH* [Dissertação de Mestrado, ISCTE-IUL]. Repositório do ISCTE-IUL. <http://hdl.handle.net/10071/19217>
- Marques, A. (2017). *Desafios na Previsão de Séries Temporais Financeiras: O caso da Taxa de Câmbio EUR/USD* [Dissertação de Mestrado, Universidade de Lisboa]. Repositório da Universidade de Lisboa. <http://hdl.handle.net/10451/30341>
- Mendes, J. (2019). *Forecasting bitcoin prices: ARIMA vs LSTM* [Dissertação de Mestrado, ISCTE-IUL]. Repositório do ISCTE-IUL. <http://hdl.handle.net/10071/19724>
- Mills, T. C. (2019). *Applied Time Series Analysis: A Practical Guide to Modeling and Forecasting*. Academic Press, an imprint of Elsevier. <https://doi.org/10.1016/C2016-0-03956-6>
- Mota, A.G. (2017). *Determinantes da Taxa de Câmbio*. Repositório do ISCTE-IUL. <http://hdl.handle.net/10071/13749>
- Mustapa, F. H., & Ismail, M. T. (2019). Modelling and forecasting S&P 500 stock prices using hybrid Arima-GARCH model. *Journal of Physics: Conference Series*, 1366. <https://doi.org/10.1088/1742-6596/1366/1/012130>
- Olakorede, N. M., Olanrewaju, S. O., & Ugbede, M. Y. (2018). A univariate time series autoregressive integrated moving average model for the exchange rate between nigerian naira and US dollar. *American Journal of Theoretical and Applied Statistics*, 7(5), 173–179. <https://doi.org/10.11648/j.ajtas.20180705.12>

- Plakandaras, V., Papadimitriou, T., & Gogas, P. (2015). Forecasting daily and monthly exchange rates with Machine Learning Techniques. *Journal of Forecasting*, 34(7), 560–573. <https://doi.org/10.1002/for.2354>
- Rosalsky, G. (2019, July 30). 75 years ago the U.S. dollar became the world’s currency. Will that last? *NPR*. <https://www.npr.org/sections/money/2019/07/30/746337868/75-years-ago-the-u-s-dollar-became-the-worlds-currency-will-that-last>
- Sharma, S., Yadav, M. P., & Jha, B. (2022). Impact of the COVID-19 outbreak on the currency exchanges of selected countries. *International Journal of Sociotechnology and Knowledge Development*, 14(2), 73–91. <https://doi.org/10.4018/ijskd.2022040105>
- The World Bank. (2022, September 29). *The World Bank In China*. <https://www.worldbank.org/en/country/china/overview>
- Xiang, Y. (2022). Using ARIMA-GARCH model to analyze fluctuation law of International Oil Price. *Mathematical Problems in Engineering*, 2022, 1–7. <https://doi.org/10.1155/2022/3936414>
- Ye, W., & Duo, W. (2019). Autonomous Forex Trading Agents. *Proceedings of the 2019 3rd International Conference on Advances in Image Processing*, 205–210. <https://doi.org/10.1145/3373419.3373436>

Anexos

Anexo A

SARIMAX Results						
=====						
Dep. Variable:	EUR/CNY		No. Observations:	241		
Model:	ARIMA(0, 0, 1)		Log Likelihood	597.958		
Date:	Tue, 20 Sep 2022		AIC	-1189.916		
Time:	03:03:47		BIC	-1179.461		
Sample:	02-28-2002		HQIC	-1185.704		
	- 02-28-2022					
Covariance Type:	opg					
=====						
	coef	std err	z	P> z	[0.025	0.975]

const	-9.089e-05	0.002	-0.054	0.957	-0.003	0.003
ma.L1	0.2918	0.065	4.459	0.000	0.164	0.420
sigma2	0.0004	3.03e-05	13.501	0.000	0.000	0.000
=====						
Ljung-Box (L1) (Q):		0.02	Jarque-Bera (JB):	10.55		
Prob(Q):		0.88	Prob(JB):	0.01		
Heteroskedasticity (H):		0.47	Skew:	0.03		
Prob(H) (two-sided):		0.00	Kurtosis:	4.02		
=====						

FIGURA 3.15. Modelo MA(1) para a série RetLogEURCNY

Anexo B

SARIMAX Results						
=====						
Dep. Variable:	EUR/USD		No. observations:	241		
Model:	ARIMA(0, 0, 1)		Log Likelihood	593.271		
Date:	Tue, 20 Sep 2022		AIC	-1180.541		
Time:	03:06:50		BIC	-1170.087		
Sample:	02-28-2002		HQIC	-1176.330		
	- 02-28-2022					
Covariance Type:	opg					
=====						
	coef	std err	z	P> z	[0.025	0.975]

const	0.0010	0.002	0.584	0.559	-0.002	0.004
ma.L1	0.3046	0.068	4.466	0.000	0.171	0.438
sigma2	0.0004	3.19e-05	13.351	0.000	0.000	0.000
=====						
Ljung-Box (L1) (Q):	0.05		Jarque-Bera (JB):	9.43		
Prob(Q):	0.82		Prob(JB):	0.01		
Heteroskedasticity (H):	0.46		Skew:	-0.04		
Prob(H) (two-sided):	0.00		Kurtosis:	3.97		
=====						

FIGURA 3.16. Modelo MA(1) para a série RetLogEURUSD

Anexo C

Dep. Variable:	EUR/CNY	No. Observations:	200
Model:	ARIMA(0, 1, 1)	Log Likelihood	45.427
Date:	Sun, 16 Oct 2022	AIC	-86.853
Time:	17:08:40	BIC	-80.266
Sample:	01-31-2002	HQIC	-84.187
	- 08-31-2018		
Covariance Type:	opg		
	coef	std err	z P> z [0.025 0.975]
ma.L1	0.3278	0.074	4.439 0.000 0.183 0.473
sigma2	0.0371	0.003	12.174 0.000 0.031 0.043
Ljung-Box (L1) (Q):	0.01	Jarque-Bera (JB):	8.06
Prob(Q):	0.93	Prob(JB):	0.02
Heteroskedasticity (H):	0.50	Skew:	-0.03
Prob(H) (two-sided):	0.01	Kurtosis:	3.98

FIGURA 3.17. Modelo ARIMA(0,1,1) para o conjunto de treino da série EUR/CNY

Dep. Variable:	EUR/USD	No. Observations:	200
Model:	ARIMA(0, 1, 1)	Log Likelihood	429.281
Date:	Sun, 16 Oct 2022	AIC	-854.562
Time:	17:08:52	BIC	-847.975
Sample:	01-31-2002	HQIC	-851.896
	- 08-31-2018		
Covariance Type:	opg		
	coef	std err	z P> z [0.025 0.975]
ma.L1	0.3122	0.076	4.083 0.000 0.162 0.462
sigma2	0.0008	6.39e-05	12.250 0.000 0.001 0.001
Ljung-Box (L1) (Q):	0.03	Jarque-Bera (JB):	10.06
Prob(Q):	0.85	Prob(JB):	0.01
Heteroskedasticity (H):	0.80	Skew:	-0.18
Prob(H) (two-sided):	0.36	Kurtosis:	4.04

FIGURA 3.18. Modelo ARIMA(0,1,1) para o conjunto de treino da série EUR/USD

Anexo D

Dep. Variable:	None	R-squared:	0.000
Mean Model:	Constant Mean	Adj. R-squared:	0.000
Vol Model:	GARCH	Log-Likelihood:	25.0830
Distribution:	Normal	AIC:	-42.1659
Method:	Maximum Likelihood	BIC:	-28.9727
		No. Observations:	200
Date:	Wed, Oct 19 2022	Df Residuals:	199
Time:	15:29:05	Df Model:	1

Mean Model

	coef	std err	t	P> t	95.0% Conf. Int.
mu	5.5815e-05	1.411e-02	3.957e-03	0.997	[-2.759e-02,2.770e-02]

Volatility Model

	coef	std err	t	P> t	95.0% Conf. Int.
omega	0.0153	4.897e-03	3.122	1.798e-03	[5.689e-03,2.488e-02]
alpha[1]	4.7241e-10	2.289e-02	2.064e-08	1.000	[-4.486e-02,4.486e-02]
beta[1]	0.5886	0.137	4.284	1.835e-05	[0.319,0.858]

FIGURA 3.19. Modelo GARCH(1,1) para os resíduos do modelo ARIMA(0,1,1) da série EUR/CNY (conjunto de treino)

Dep. Variable:	None	R-squared:	0.000
Mean Model:	Constant Mean	Adj. R-squared:	0.000
Vol Model:	GARCH	Log-Likelihood:	398.888
Distribution:	Normal	AIC:	-789.777
Method:	Maximum Likelihood	BIC:	-776.583
		No. Observations:	200
Date:	Wed, Oct 19 2022	Df Residuals:	199
Time:	15:29:06	Df Model:	1

Mean Model

	coef	std err	t	P> t	95.0% Conf. Int.
mu	9.8193e-04	1.704e-03	0.576	0.565	[-2.358e-03,4.322e-03]

Volatility Model

	coef	std err	t	P> t	95.0% Conf. Int.
omega	9.1518e-05	4.541e-05	2.015	4.387e-02	[2.515e-06,1.805e-04]
alpha[1]	0.1957	0.108	1.804	7.118e-02	[-1.688e-02,0.408]
beta[1]	0.7631	4.664e-02	16.360	3.681e-60	[0.672,0.854]

FIGURA 3.20. Modelo GARCH(1,1) para os resíduos do modelo ARIMA(0,1,1) da série EUR/USD (conjunto de treino)

Anexo E

EUR/CNY	ARIMA(0,1,1)	ARIMA(0,1,1)-GARCH(1,1)	Random Walk	Prophet	Valor Real
30/09/2018	7.89923437	7.944055216	7.9092	7.47423	7.993
31/10/2018	8.02359658	8.072904599	7.894735	7.5301	7.9481
30/11/2018	7.92355791	7.971674478	7.891731	7.50408	7.888
31/12/2018	7.87642167	7.923276605	7.875431	7.56718	7.8398
31/01/2019	7.82785726	7.873754017	7.897543	7.54375	7.7504
28/02/2019	7.72511929	7.7709743	7.853629	7.4123	7.6485
31/03/2019	7.62345848	7.668818978	7.84251	7.453	7.5868
30/04/2019	7.57480908	7.619154572	7.897093	7.53393	7.5489
31/05/2019	7.54042112	7.5841021	7.908731	7.62677	7.6736
30/06/2019	7.71714555	7.761057086	7.925643	7.58087	7.7937
31/07/2019	7.81876786	7.861843405	7.950774	7.5652	7.7151
31/08/2019	7.68112021	7.723512912	7.952062	7.54293	7.8581
30/09/2019	7.91564757	7.959353747	7.958204	7.44134	7.8323
31/10/2019	7.80545482	7.849640396	7.97221	7.56992	7.8447
30/11/2019	7.85734666	7.900648353	7.993288	7.55132	7.7571
31/12/2019	7.7248379	7.767256392	7.969073	7.5778	7.7974
31/01/2020	7.82065814	7.862772412	7.96589	7.61469	7.6832
29/02/2020	7.63935204	7.680897286	7.955457	7.5757	7.6302
31/03/2020	7.6272847	7.668544343	7.967206	7.58896	7.7675
30/04/2020	7.81240047	7.853114987	7.962467	7.55126	7.6858
31/05/2020	7.64553638	7.687048164	7.93211	7.50603	7.7482
30/06/2020	7.7806189	7.821448929	7.939098	7.52625	7.9734
31/07/2020	8.03492469	8.075070302	7.941692	7.60723	8.0352
31/08/2020	8.03528764	8.075052666	7.942448	7.60807	8.1954
30/09/2020	8.24649848	8.285983963	7.972749	7.61668	8.0333
31/10/2020	7.96632313	8.005354235	7.99826	7.52896	7.9225
30/11/2020	7.90873932	7.94748548	8.00816	7.48425	7.8152
31/12/2020	7.78564221	7.824165793	8.045081	7.62049	7.9602
31/01/2021	8.01495644	8.053230047	8.037667	7.474	7.873
28/02/2021	7.82906335	7.867002259	8.004828	7.54712	7.8136
31/03/2021	7.8088087	7.846439292	8.037481	7.56774	7.7465
30/04/2021	7.72712853	7.765084168	8.03814	7.56874	7.8051
31/05/2021	7.82928189	7.866686474	8.030512	7.57048	7.8109
30/06/2021	7.80520517	7.842230991	8.010365	7.57021	7.7391
31/07/2021	7.71858026	7.757588555	8.000045	7.61916	7.6536
31/08/2021	7.63340674	7.672117516	7.968211	7.61197	7.6237
30/09/2021	7.62068302	7.659268959	7.973191	7.58232	7.6007
31/10/2021	7.59448744	7.632659405	7.939279	7.56607	7.45
30/11/2021	7.40503396	7.442695914	7.926101	7.53134	7.2927
31/12/2021	7.25762588	7.299247289	7.927882	7.63102	7.1993
31/01/2022	7.18103677	7.223122821	7.915843	7.54646	7.1922
28/02/2022	7.19569639	7.242819759	7.940901	7.51744	7.1957

TABELA 3.22. Valores previstos por cada modelo para a série EUR/CNY

Anexo F

EUR/USD	ARIMA(0,1,1)	ARIMA(0,1,1)-GARCH(1,1)	Random Walk	Prophet	Valor Real
30/09/2018	1.15056262	1.151216888	1.1549	1.09448	1.1659
31/10/2018	1.17066882	1.171388841	1.140435	1.1	1.1484
30/11/2018	1.14153393	1.142234069	1.137431	1.0923	1.1367
31/12/2018	1.13520944	1.135900992	1.121131	1.09451	1.1384
31/01/2019	1.13938817	1.140068744	1.143243	1.08823	1.1416
28/02/2019	1.14228512	1.142964515	1.099329	1.07158	1.1351
31/03/2019	1.13287466	1.133547613	1.08821	1.07041	1.1302
30/04/2019	1.12937158	1.130030568	1.142793	1.07934	1.1238
31/05/2019	1.12207389	1.12272294	1.154431	1.08996	1.1185
30/06/2019	1.1173926	1.118043575	1.171343	1.08193	1.1293
31/07/2019	1.13298902	1.133628162	1.196474	1.07593	1.1218
31/08/2019	1.11834476	1.118975388	1.197762	1.0681	1.1126
30/09/2019	1.11082392	1.112513966	1.203904	1.05088	1.1004
31/10/2019	1.09717248	1.097828304	1.21791	1.06811	1.1053
30/11/2019	1.10781207	1.108455059	1.238988	1.06284	1.1051
31/12/2019	1.10426225	1.104892432	1.214773	1.05886	1.1113
31/01/2020	1.11347311	1.114503383	1.21159	1.06053	1.11
29/02/2020	1.10892838	1.110474889	1.201157	1.05258	1.0905
31/03/2020	1.08480143	1.085414985	1.212906	1.05474	1.1063
30/04/2020	1.11290037	1.114460819	1.208167	1.04968	1.0862
31/05/2020	1.07811598	1.078734593	1.17781	1.03537	1.0902
30/06/2020	1.09382369	1.094433568	1.184798	1.0333	1.1255
31/07/2020	1.13514835	1.136119023	1.187392	1.0402	1.1463
31/08/2020	1.14971066	1.150306683	1.188148	1.04105	1.1828
30/09/2020	1.1929722	1.19438067	1.218449	1.04352	1.1792
31/10/2020	1.17502023	1.176376227	1.24396	1.02598	1.1775
30/11/2020	1.17825385	1.17888088	1.25386	1.0128	1.1838
31/12/2020	1.18549138	1.186942864	1.290781	1.02733	1.217
31/01/2021	1.22662737	1.228143224	1.283367	1.00487	1.2171
28/02/2021	1.21421689	1.215515165	1.250528	1.01293	1.2098
31/03/2021	1.20845747	1.21002691	1.283181	1.01375	1.1899
30/04/2021	1.18425134	1.185860477	1.28384	1.01317	1.1979
31/05/2021	1.20202927	1.203546437	1.276212	1.00727	1.2146
30/06/2021	1.21841811	1.21982142	1.256065	1.00346	1.2047
31/07/2021	1.20053227	1.201183689	1.245745	1.00614	1.1822
31/08/2021	1.17660974	1.177252841	1.213911	1.00407	1.1772
30/09/2021	1.17737997	1.178022909	1.218891	0.99972	1.177
31/10/2021	1.17688399	1.178595318	1.184979	0.99364	1.1601
30/11/2021	1.154974	1.15560156	1.171801	0.9833	1.1414
31/12/2021	1.13724496	1.137978827	1.173582	0.99169	1.1304
31/01/2022	1.12830081	1.129115936	1.161543	0.97736	1.1314
28/02/2022	1.13235052	1.136752175	1.186601	0.9731	1.1342

TABELA 3.23. Valores previstos por cada modelo para a série EUR/USD

Anexo G

Dep. Variable:	EUR/CNY	No. Observations:	199			
Model:	ARIMA(0, 0, 1)	Log Likelihood	481.656			
Date:	Thu, 20 Oct 2022	AIC	-957.311			
Time:	00:59:19	BIC	-947.431			
Sample:	02-28-2002	HQIC	-953.313			
	- 08-31-2018					
Covariance Type:	opg					
	coef	std err	z	P> z	[0.025	0.975]
const	0.0004	0.002	0.182	0.855	-0.004	0.004
ma.L1	0.3076	0.075	4.125	0.000	0.161	0.454
sigma2	0.0005	3.94e-05	11.733	0.000	0.000	0.001
Ljung-Box (L1) (Q):	0.01	Jarque-Bera (JB):	4.93			
Prob(Q):	0.92	Prob(JB):	0.09			
Heteroskedasticity (H):	0.81	Skew:	-0.02			
Prob(H) (two-sided):	0.39	Kurtosis:	3.77			

FIGURA 3.21. Modelo MA(1) para o conjunto de treino da série RetLogEURCNY

Dep. Variable:	EUR/USD	No. Observations:	199			
Model:	ARIMA(0, 0, 1)	Log Likelihood	477.218			
Date:	Thu, 20 Oct 2022	AIC	-948.436			
Time:	01:01:07	BIC	-938.556			
Sample:	02-28-2002	HQIC	-944.437			
	- 08-31-2018					
Covariance Type:	opg					
	coef	std err	z	P> z	[0.025	0.975]
const	0.0013	0.002	0.633	0.527	-0.003	0.005
ma.L1	0.3110	0.078	3.970	0.000	0.157	0.465
sigma2	0.0005	4.2e-05	11.498	0.000	0.000	0.001
Ljung-Box (L1) (Q):	0.05	Jarque-Bera (JB):	3.91			
Prob(Q):	0.82	Prob(JB):	0.14			
Heteroskedasticity (H):	0.81	Skew:	-0.08			
Prob(H) (two-sided):	0.40	Kurtosis:	3.67			

FIGURA 3.22. Modelo MA(1) para o conjunto de treino da série RetLogEURUSD

Anexo H

Dep. Variable:	None	R-squared:	0.000
Mean Model:	Constant Mean	Adj. R-squared:	0.000
Vol Model:	GARCH	Log-Likelihood:	484.497
Distribution:	Normal	AIC:	-960.995
Method:	Maximum Likelihood	BIC:	-947.821
No. Observations:			199
Date:	Wed, Oct 19 2022	Df Residuals:	198
Time:	15:29:10	Df Model:	1

Mean Model

	coef	std err	t	P> t	95.0% Conf. Int.
mu	5.1534e-04	1.442e-03	0.357	0.721	[-2.310e-03, 3.341e-03]

Volatility Model

	coef	std err	t	P> t	95.0% Conf. Int.
omega	5.5034e-05	1.078e-05	5.107	3.270e-07	[3.391e-05, 7.615e-05]
alpha[1]	0.0766	4.946e-02	1.549	0.121	[-2.031e-02, 0.174]
beta[1]	0.8038	4.401e-02	18.259	1.751e-74	[0.717, 0.890]

FIGURA 3.23. Modelo GARCH(1,1) para os resíduos do modelo MA(1) da série RetLogEURCNY (conjunto de treino)

Dep. Variable:	None	R-squared:	0.000
Mean Model:	Constant Mean	Adj. R-squared:	0.000
Vol Model:	GARCH	Log-Likelihood:	478.804
Distribution:	Normal	AIC:	-949.607
Method:	Maximum Likelihood	BIC:	-936.434
No. Observations:			199
Date:	Wed, Oct 19 2022	Df Residuals:	198
Time:	15:29:11	Df Model:	1

Mean Model

	coef	std err	t	P> t	95.0% Conf. Int.
mu	2.4986e-04	1.517e-03	0.165	0.869	[-2.723e-03, 3.223e-03]

Volatility Model

	coef	std err	t	P> t	95.0% Conf. Int.
omega	5.2420e-05	7.205e-06	7.276	3.451e-13	[3.830e-05, 6.654e-05]
alpha[1]	0.0464	3.456e-02	1.344	0.179	[-2.130e-02, 0.114]
beta[1]	0.8440	3.030e-02	27.852	1.005e-170	[0.785, 0.903]

FIGURA 3.24. Modelo GARCH(1,1) para os resíduos do modelo MA(1) da série RetLogEURUSD (conjunto de treino)

Anexo I

RetLogEURCNY	MA(1)	MA(1)-GARCH(1,1)	Random Walk	Prophet
30/09/2018	-0.00079996	-0.000225293	0.007462153	-0.00548
31/10/2018	0.00388384	0.004409377	0.004424414	-0.00136
30/11/2018	-0.00250857	-0.00200359	0.003793732	-0.00823
31/12/2018	-0.00120382	-0.000711499	0.000370701	0.005583
31/01/2019	-0.00119199	-0.00069919	0.005014274	-0.00639
28/02/2019	-0.00288988	-0.002401867	-0.00420773	-0.0061
31/03/2019	-0.00298276	-0.002505993	-0.00654274	-0.0012
30/04/2019	-0.00142071	-0.000960766	0.004919709	-0.00042
31/05/2019	-0.00097699	-0.000513601	0.007363759	0.000884
30/06/2019	0.00553168	0.005986766	0.010915094	-0.00368
31/07/2019	0.00335173	0.003799943	0.016192766	0.000624
31/08/2019	-0.00392709	-0.003469491	0.016463132	-0.00331
30/09/2019	0.00709983	0.007561765	0.017752899	-0.00581
31/10/2019	-0.00282971	-0.00237638	0.020694307	-0.00136
30/11/2019	0.00162928	0.002074341	0.025120528	-0.00845
31/12/2019	-0.00361746	-0.003174664	0.020035493	0.005138
31/01/2020	0.00290262	0.003340777	0.019367028	-0.00669
29/02/2020	-0.00504606	-0.004611681	0.0171761	-0.00626
31/03/2020	-0.00038461	4.40479E-05	0.019643318	-0.00139
30/04/2020	0.0056924	0.006128367	0.018648272	-0.00098
31/05/2020	-0.00460762	-0.004178505	0.012273354	0.000209
30/06/2020	0.00395352	0.004376038	0.013740825	-0.00372
31/07/2020	0.00770316	0.008023795	0.014285577	0.000659
31/08/2020	0.00040322	0.000715673	0.014444211	-0.00341
30/09/2020	0.00622789	0.006554896	0.02080741	-0.00589
31/10/2020	-0.00723957	-0.006849274	0.026164649	-0.00245
30/11/2020	-0.00160868	-0.001213596	0.028243739	-0.00891
31/12/2020	-0.00326651	-0.002875539	0.035997136	0.005365
31/01/2021	0.00665162	0.00703788	0.034440241	-0.00688
28/02/2021	-0.00475697	-0.004375371	0.027544041	-0.00657
31/03/2021	-0.00054142	-0.000156689	0.034401085	-0.00169
30/04/2021	-0.00210117	-0.001722625	0.034539644	-0.00116
31/05/2021	0.00302496	0.003399392	0.032937646	0.000077
30/06/2021	-0.00038975	-7.81574E-05	0.028706794	-0.00407
31/07/2021	-0.00232182	-0.001934084	0.026539649	0.000288
31/08/2021	-0.00236025	-0.001973106	0.019854477	-0.00374
30/09/2021	-0.00029158	9.07685E-05	0.020900337	-0.00623
31/10/2021	-0.00064215	-0.000266411	0.013778731	-0.00245

30/11/2021	-0.00553967	-0.00513437	0.011011347	-0.00911
31/12/2021	-0.00462249	-0.004201663	0.01138534	0.004936
31/01/2022	-0.00250017	-0.001728101	0.008857241	-0.00718
28/02/2022	0.00035211	0.001066917	0.01411928	-0.00688

TABELA 3.24. Valores previstos por cada modelo para a série RetLogEURCNY

Anexo J

RetLogEURUSD	MA(1)	MA(1)-GARCH(1,1)	Random Walk	Prophet
30/09/2018	-0.00274198	-0.002169283	-0.01179269	-0.00596
31/10/2018	0.00513829	0.005659009	-0.01483043	-0.00309
30/11/2018	-0.00493745	-0.004427734	-0.01546111	-0.01071
31/12/2018	-0.00040952	8.94013E-05	-0.01888414	0.001895
31/01/2019	0.00180494	0.002302303	-0.01424057	-0.00639
28/02/2019	0.00153462	0.002026532	-0.02346257	-0.00761
31/03/2019	-0.00104254	-0.000562823	-0.02579759	-0.004
30/04/2019	0.00015394	0.000626326	-0.01433514	-0.00186
31/05/2019	-0.00066577	-0.000192651	-0.01189108	-0.00262
30/06/2019	-0.00015005	0.00030724	-0.00833975	-0.00706
31/07/2019	0.00415655	0.004607565	-0.00306208	-0.00312
31/08/2019	-0.00221505	-0.001746546	-0.00279171	-0.00598
30/09/2019	-0.00078545	-0.000317195	-0.00150195	-0.0067
31/10/2019	-0.002148	-0.001693724	0.001439463	-0.00362
30/11/2019	0.00305136	0.003497541	0.005865684	-0.01134
31/12/2019	2.1665E-05	0.00046332	0.000780649	0.001078
31/01/2020	0.00275125	0.003187336	0.000112184	-0.00718
29/02/2020	-0.00017732	0.000257053	-0.00207874	-0.00831
31/03/2020	-0.00446334	-0.004033415	0.000388474	-0.00465
30/04/2020	0.0067565	0.007191363	-0.00060657	-0.00281
31/05/2020	-0.00660111	-0.00617232	-0.00698149	-0.00362
30/06/2020	0.00397025	0.004392373	-0.00551402	-0.00769
31/07/2020	0.00948796	0.009905874	-0.00496927	-0.00366
31/08/2020	0.00382044	0.004133828	-0.00481063	-0.0064
30/09/2020	0.0096693	0.010011312	0.001552566	-0.00731
31/10/2020	-0.00255609	-0.002165533	0.006909805	-0.0049
30/11/2020	0.00158531	0.001872534	0.008988895	-0.0123
31/12/2020	0.00239985	0.002721567	0.016742292	0.000649
31/01/2021	0.00902248	0.009373436	0.015185397	-0.00767
28/02/2021	-0.00129583	0.008981076	0.008289198	-0.00903
31/03/2021	-7.3505E-05	0.000317562	0.015146241	-0.00539
30/04/2021	-0.00370871	-0.003320871	0.0152848	-0.00345
31/05/2021	0.00440697	0.004789087	0.013682802	-0.00424
30/06/2021	0.00418154	0.004600315	0.00945195	-0.00843
31/07/2021	-0.00241369	-0.001999667	0.007284805	-0.00443
31/08/2021	-0.00374726	-0.003334629	0.000599633	-0.00721
30/09/2021	0.00104596	0.00138669	0.001645494	-0.00806
31/10/2021	0.00082076	0.001132527	-0.00547611	-0.00542

30/11/2021	-0.00350466	-0.003059835	-0.0082435	-0.01293
31/12/2021	-0.00281997	-0.002370389	-0.0078695	-0.00015
31/01/2022	-0.00108508	-0.000495088	-0.0103976	-0.00846
28/02/2022	0.00160394	0.00219657	-0.00513556	-0.00975

TABELA 3.25. Valores previstos por cada modelo para a série RetLogEU-RUSD