

# iscte

INSTITUTO  
UNIVERSITÁRIO  
DE LISBOA

---

**Previsão de ETF no Setor de *E-commerce*: Aplicação de  
Métodos Clássicos e *Machine Learning* no Contexto de  
*Business Analytics***

Leonor Branco da Silva

Mestrado em Métodos Analíticos para a Gestão (*Business Analytics*)

Orientador:

Professor Doutor, Filipe Roberto de Jesus Ramos, Professor  
Auxiliar Convidado, ISCTE Business School

Setembro, 2025





BUSINESS  
SCHOOL

---

Departamento de Métodos Quantitativos para Gestão e  
Economia

**Previsão de ETF no Setor de *E-commerce*: Aplicação de  
Métodos Clássicos e *Machine Learning* no Contexto de  
*Business Analytics***

Leonor Branco da Silva

Mestrado em Métodos Analíticos para a Gestão (*Business  
Analytics*)

Orientador:

Professor Doutor, Filipe Roberto de Jesus Ramos, Professor  
Auxiliar Convidado, ISCTE Business School

Setembro, 2025







## **Agradecimentos**

É imprescindível exprimir a profunda gratidão ao Professor Doutor Filipe Ramos pelo seu acompanhamento, disponibilidade e conhecimento valioso que partilhou ao longo deste processo. Agradeço também, em especial, ao Professor Doutor Raul Laureano pela sua exigência positiva, entusiasmo contagiante e apoio inspirador, que me motivou ao longo de cada etapa do Mestrado em *Business Analytics*, e que se refletem também nesta investigação.

Deixo um sincero agradecimento dirigido ao ISCTE Business School pela excelência de ensino e por ter sido a minha segunda casa, durante toda a minha formação, desde a Licenciatura até ao Mestrado.

Estendo o meu profundo agradecimento a todas as pessoas que, direta ou indiretamente, fizeram parte deste percurso académico, especialmente aquelas que me apoiaram ao longo de toda esta etapa e que me motivaram ao longo de cada desafio.

Não podia deixar de mencionar, as minhas amigas, as que representam a família que eu escolhi e as irmãs que nunca tive. Vocês foram um pilar ao longo de todo este ano, agradeço-vos por terem sabotado muitos dos meus momentos de foco, garantindo momentos de diversão e risadas. Esta etapa está completa, graças às vossas distrações e o vosso carinho, mas as nossas aventuras e a nossa amizade, são a etapa que espero nunca concluir.

Por fim, o agradecimento final e inestimável à minha família. Mãe e Pai obrigada por tornarem tudo isto possível, e por moverem montanhas para que eu tivesse tudo aquilo que desejasse, esta etapa é tão minha como vossa. Mano obrigada por toda a tua energia, histórias e animação, trouxeste, como sempre, risadas e amor a toda esta aventura, e espero agora que alcances tudo isto e muito mais. Avós, tios, tias, primos e afilhado obrigada por serem a minha família, pelo vosso amor, carinho e orgulho sentido ao longo de todos estes anos.

*Tudo se faz!*



## Resumo

Os *Exchange Traded Funds* (ETF) continuam a ser um dos instrumentos financeiros mais destacados entre investidores devido à sua versatilidade, acessibilidade e fácil gestão. O interesse pelos setores emergentes associados à economia digital tem reforçado o foco por ETF especializados, como os do setor de *E-commerce*, cuja relevância tem vindo a aumentar nos últimos anos. A presente investigação tem como objetivos analisar o comportamento e o perfil de risco de três ETF representativos deste setor – EBIZ, IBUY e ONLN – e identificar quais as metodologias mais adequadas para a previsão do seu comportamento. No desenvolver do estudo são aplicadas ferramentas de exploração de dados (análise estatística, inferencial e indicadores de risco financeiro) e de análise preditiva. No âmbito de análise preditiva são implementadas duas metodologias, modelos de Alisamento Exponencial (ES) e modelos de *Support Vector Regression* (SVR), confrontando o desempenho dos modelos Clássicos em função dos modelos de *Machine Learning*. Os resultados demonstram que, apesar de três ETF com perfis de risco com idênticos, o EBIZ destacou-se pela sua melhor relação entre risco e retorno. Em termos preditivos o SVR superou o desempenho do modelo Clássico, e na avaliação da complexidade computacional, as duas metodologias apesar de registarem um equilíbrio entre limitações e vantagens, o SVR obtém a melhor classificação global. Os resultados deste estudo contribuem para a literatura sobre previsão (em mercados financeiros), destacando a relevância das metodologias de *Machine Learning* para setores emergentes como o *E-commerce*, sem deixar de evidenciar o valor dos modelos clássicos.

**Palavras-Chave:** Mercados Financeiros, *E-commerce*, Comércio digital, ETF, Risco, Análise Preditiva, Séries Temporais, Alisamento, Exponencial, *Machine Learning*, *Support Vector Regression*, *Business Analytics*.

**Classificação JEL:** C10, C40, C50



## **Abstract**

Exchange Traded Funds (ETFs) continue to be one of the most popular financial instruments among investors due to their versatility, accessibility and ease of management. Interest in emerging sectors associated with the digital economy has reinforced the focus on specialized ETFs, such as those in the e-commerce sector, whose relevance has been increasing in recent years. The objectives of this research are to analyze the behavior and risk profile of three representative ETFs in this sector – EBIZ, IBUY and ONLN – and to identify the most appropriate methodologies for predicting their behavior. Data exploration tools (statistical analysis, inferential analysis and financial risk indicators) and predictive analysis tools are applied during the study. In the context of predictive analysis, two methodologies are implemented, Exponential Smoothing Models (ES) and Support Vector Regression (SVR) Models, comparing the performance of Classical Models with Machine Learning Models. The results show that, despite three ETFs with identical risk profiles, EBIZ stood out for its better risk/return ratio. In predictive terms, SVR outperformed the Classic Model, and in the assessment of computational complexity, although both methodologies showed a balance between limitations and advantages, SVR obtained the best overall rating. The results of this study contribute to the literature about forecasting (in financial markets), highlighting the relevance of Machine Learning methodologies for emerging sectors such as E-commerce, while still showing the value of classic models.

**Keywords:** Financial Markets, E-commerce, Digital Commerce, ETF, Risk, Predictive Analysis, Time Series, Smoothing, Exponential, Machine Learning, Support Vector Regression, Business Analytics.

**JEL Classification:** C10, C40, C50



## Índice

Agradecimentos .....	i
Resumo .....	iii
Abstract .....	v
Índice de Figuras .....	ix
Índice de Tabelas .....	x
1. Introdução .....	1
2. Revisão de Literatura .....	5
2.1. O Impacto do <i>E-commerce</i> na Transformação Digital .....	5
2.2. A Evolução e Relevância dos <i>Exchange Traded Funds</i> no Mercado Financeiro .....	6
2.3. <i>Exchange Traded Funds</i> no setor de <i>E-commerce</i> : Potencial de Investimento .....	8
2.4. Previsão de séries temporais no contexto do Mercado Financeiro .....	9
2.4.1. Metodologias clássicas de previsão de séries temporais .....	11
2.4.2. Metodologias <i>Machine Learning</i> de previsão de séries temporais .....	12
2.4.3. Metodologias <i>Deep Learning</i> de previsão de séries temporais .....	14
2.5. Confronto de Evidências: Métodos de Previsão na Literatura Científica .....	16
3. Metodologia .....	19
3.1. Compreensão do negócio .....	19
3.2. Compreensão dos dados .....	19
3.2.1. Bases de dados .....	19
3.2.2. Verificação da qualidade dos Dados .....	20
3.2.3. Descrição e exploração dos Dados .....	21
3.3. Preparação dos Dados .....	22
3.4. Implementação dos Modelos .....	22
3.4.1. Modelo Estatístico: Alisamento Exponencial (ES) .....	23
3.4.2. Modelo de <i>Machine Learning</i> : <i>Support Vector Regression</i> (SVR) .....	24
3.5. Seleção, validação e avaliação dos Modelos .....	25
3.6. Comparação dos Modelos .....	26
3.7. Implementação Computacional .....	27
4. Resultados .....	29
4.1. Análise Exploratória dos ETF de <i>E-commerce</i> .....	29
4.2. Análise de Risco dos ETF de <i>E-commerce</i> .....	32
4.3. Modelação e Previsão das Séries Temporais .....	34
4.3.1. Modelos de Alisamento Exponencial (ES) .....	34

4.3.2. Modelos de SVR.....	37
4.4. Comparação e Discussão do desempenho das diferentes Metodologias .....	39
5. Conclusões.....	43
5.1. Limitações e recomendações para investigações futuras.....	45
Referências bibliográficas (APA <i>style</i> ) .....	49
Anexos .....	53

## Índice de Figuras

<b>Fig. 1-</b> Evolução Temporal dos ETF de E-commerce .....	29
<b>Fig. 2-</b> Distribuição dos preços de fecho da EBIZ nos últimos 36 meses da série .....	31
<b>Fig. 3-</b> Distribuição dos preços de fecho da IBUY nos últimos 36 meses da série .....	31
<b>Fig. 4-</b> Distribuição dos preços de fecho da ONLN nos últimos 36 meses da série.....	32
<b>Fig. 5 -</b> Relação entre Retorno e Volatilidade, considerando os pesos do Sharpe Ratio .....	33
<b>Fig. 6-</b> Comparação da evolução do Risco de perda máxima entre os três ETF .....	33
<b>Fig. 7-</b> ES (N,N) EBIZ - Comparação entre os valores previstos e observados.....	36
<b>Fig. 8 -</b> ES (N,N) IBUY - Comparação entre os valores previstos e observados .....	36
<b>Fig. 9-</b> ES (N,N) ONLN - Comparação entre os valores previstos e observados.....	36
<b>Fig. 10 -</b> SVR 3 EBIZ (C=10; $\epsilon =0.01$ ) - Comparação dos valores previstos e observados ...	38
<b>Fig. 11 -</b> SVR 3 IBUY (C=10; $\epsilon =0.01$ ) - Comparação dos valores previstos e observados ...	38
<b>Fig. 12 -</b> SVR 3 ONLN (C=10; $\epsilon =0.01$ ) - Comparação dos valores previstos e observados .	38
<b>Fig. 13 -</b> Categorias de Risco segundo a Volatilidade e o Retorno Anualizado .....	40

## Índice de Tabelas

<b>Tabela 1</b> - Classificação dos Modelos dos Modelos de Alisamento Exponencial .....	24
<b>Tabela 2</b> - Análise Inferencial: Testes de normalidade, estacionaridade e independência .....	30
<b>Tabela 3</b> - Análise Inferencial aos Resíduos dos Modelos TS(N,N): Testes de normalidade, variância e independência .....	35
<b>Tabela 4</b> - Análise do Desempenho dos Modelos TS (N,N) na amostra de teste.....	36
<b>Tabela 5</b> - Análise do Desempenho dos Modelos SVR nas amostras de teste .....	39
<b>Tabela 6</b> - Análise quantitativa da capacidade preditiva das diferentes metodologias .....	41
<b>Tabela 7</b> - Análise qualitativa das diferentes metodologias .....	41

## 1. Introdução

No Mercado Financeiro é possível encontrar uma ampla variedade de produtos, cada um destes, adequado aos diferentes perfis de investidores, desde ações e criptomoedas a *Real Estate Investment Trusts* (REIT) e *Exchange Traded Funds* (ETF). Entre os diferentes produtos financeiros transacionados em bolsa, os ETF têm vindo a destacar-se cada vez mais, dominando o cenário global de investimentos (Atilgan *et al.*, 2024; Joshi e Kumar Dash, 2024; Fonseca, 2012).

No *The 2024 J.P. Morgan 2024 Global ETF Handbook* (Kolanovic e Kaplan, 2024), 20ª edição anual, é evidenciado o potencial destes ativos. Segundo os autores, Kolanovic e Kaplan (2024), apesar do amadurecimento deste mercado e da diminuição da sua taxa de crescimento anual, a valorização global do mercado global de ETF registou, em maio de 2024, um aumento de cerca de 10.1 mil milhões de dólares, em comparação com o ano anterior, refletindo a crescente procura e interesse por estes produtos. Entre as diferentes características que distinguem os ETF dos restantes ativos transacionados em bolsa, a que mais se destaca é a possibilidade do investidor, dependendo do seu perfil de risco e dos seus interesses, investir em ETF de um setor específico ou diversificado como o SPY, o ETF que replica o índice S&P500.

Contudo, antes de se alocar qualquer investimento a estes produtos financeiros é importante avaliar os seus riscos, as suas vantagens e as suas características e, definir objetivos de investimento (Najem e Amr, *et al.*, 2024). O *Business Analytics*, compilando a análise de dados e a previsão de séries temporais, torna-se uma ferramenta essencial para estudar estes ativos, sendo, através destes métodos, possível antecipar as variações de preços destes ativos e criar um plano de investimento, controlando os gastos e riscos associados aos mesmos (Najem e Amr, *et al.*, 2024).

Para a seleção dos ativos a analisar, na ótica desta investigação, procurou-se entender que temas se sobressaíam atualmente, de modo a encontrar empresas ou setores que demonstrassem oportunidades de crescimento. Durante esta investigação surgem dois temas com maior destaque, a digitalização e a tecnologia, dois setores em forte expansão, como apontado por Hoque *et al.*, 2024. Os ETF inseridos na economia digital, surgem aliados a estes dois conceitos e são constituídos por ações de empresas que dependem da tecnologia digital e/ou vendem produtos digitais (Hoque *et al.*, 2024). Compreendida a relevância da economia digital, este estudo tem como foco a análise de três séries temporais diárias de ETF no setor de *E-commerce* (EBIZ, IBUY e ONLN), para o período de janeiro de 2019 a abril de 2025.

O *E-commerce* tem vindo a revolucionar os conceitos tradicionais de comércio e os métodos de contactos com os clientes (Kalıpcı *et al.*, 2024). Como consequência da pandemia Covid-19, o comércio eletrónico sofreu um crescimento acelerado, com repercussões que se verificam até aos dias de

hoje, sendo destacado por muitos investigadores como um setor com tendências de crescimento Higuera-Castillo *et al.* (2023). Sendo o *E-commerce* caracterizado pela troca de bens e serviços com recurso à Internet (Pavlou, 2003), é possível classificar-se os ETF deste setor como ETF da economia digital, refletindo o desempenho de empresas ligadas ao comércio eletrónico.

Observado o potencial dos ETF e do Setor de *E-commerce* definiu-se o tema desta investigação, motivado pelo interesse de compreender o potencial de investimento associado a estes ativos e a este setor, e pelo interesse da exploração e modelação de séries temporais. Além destes pontos, na fase inicial de contextualização acerca do tema, foi possível destacar uma lacuna de investigações na ótica de previsão de ETF em setores específicos e dinâmicos, como os associados à digitalização.

Pretende-se, assim com esta investigação contribuir para o conhecimento científico sobre a previsão de séries temporais financeiras com foco em ETF de setores emergentes, como o *E-commerce*. Com o intuito de atingir este objetivo procurar-se-á responder às seguintes questões de investigação:

- (i) De que forma se caracterizam, em termos estatísticos, as séries temporais dos ETF do setor de *E-commerce*?
- (ii) Quais as metodologias de modelação mais adequadas, em termos de desempenho preditivo e eficiência computacional, para a previsão do comportamento de ETF do setor de *E-commerce*?

Este estudo será realizado recorrendo a técnicas reconhecidas pelo seu desempenho na previsão de séries temporais, aplicadas aos mercados financeiros, utilizando técnicas Clássicas e de *Machine Learning*, acrescentando assim, valor para o conhecimento científico, para a comunidade académica, e, para os profissionais da área em investigação.

A análise de dados financeiros baseou-se durante muitos anos em modelos estatísticos, abordagens estas que trouxeram contributos muito significativos para a literatura financeira, e que, ainda hoje são aplicados em contextos reais. Porém, estes métodos evidenciam algumas limitações quando aplicadas ao contexto dos mercados financeiros, limitações estas que devido à evolução e aumento da computacional foram ultrapassadas através de Metodologias baseadas em Inteligência Artificial (AI) como o *Machine Learning*. Estes modelos, suportados por avanços em AI, redefiniram a previsão de preços de mercado, ao permitirem lidar com padrões dinâmicos, relações ocultas e estruturas temporais complexas (Najem, Bahnasse, *et al.*, 2024).

Neste sentido, analisar o comportamento dos ETF com base nos seus dados históricos, é essencial para modelar corretamente os comportamentos deste mercado e definir as estratégias de previsão que mais se adequam aos padrões das séries em estudo. De forma complementar esta análise exploratória permitirá fornecer informações valiosas, para investidores institucionais e individuais, acerca

destes fundos de investimento, fornecendo recomendações práticas e insights sobre os riscos potenciais e vantagens destes ativos.

Em termos de estrutura, esta investigação está organizada em cinco capítulos, iniciando-se com a introdução e terminando com a conclusão e considerações para investigações futuras. O Capítulo 2 apresenta a Revisão de Literatura, com a contextualização acerca dos ETF e do *E-commerce*, bem como a relação entre ambos. Neste Capítulo são também abordadas as diferentes metodologias aplicadas no contexto de previsão de preços de mercado, desde os modelos clássicos aos modelos baseados em Inteligência Artificial. Considerando os diferentes estudos e resultados reportados pelos diferentes autores foi incluída uma secção que confronta as diferentes evidências encontradas na literatura, encerrando assim a Revisão de Literatura.

No Capítulo 3 são descritos os procedimentos práticos e metodológicos adotados neste estudo, seguindo a metodologia CRISP-DM, este Capítulo divide-se em seis fases: a compreensão do negócio e dos dados, a preparação dos dados, a implementação dos modelos e a sua seleção, avaliação e validação. Adicionalmente, para complementar a evidências de reposta à segunda questão de investigação, acrescentou-se a secção de comparação dos modelos, onde é desenvolvida uma análise quantitativa e qualitativa das diferentes metodologias. Para concluir este capítulo, foi adicionada uma secção referente à implementação computacional, com o intuito de destacar as principais bibliotecas utilizadas para o desenvolvimento deste estudo e explicar a estruturação dos *notebooks*, facilitando a replicação por outros estudos no meio académico/científico ou profissional.

O Capítulo 4 destina-se à exposição dos resultados desta investigação de forma estruturada, segundo a metodologia CRISP-DM, e subdivididas pelas três séries temporais, permitindo a identificação clara das evidências para responder às questões de investigação proposta por este estudo. Por fim, no Capítulo 5 são compiladas todas as conclusões obtidas nas diferentes secções e são apresentadas as limitações e recomendações para as investigações futuras.



## 2. Revisão de Literatura

### 2.1. O Impacto do *E-commerce* na Transformação Digital

O Comércio Eletrônico, ou *E-commerce*, é um tipo de comércio que se define pela troca de bens e serviços com recurso à Internet (Pavlou, 2003). Este novo conceito de comércio tem causado impacto no modo de funcionamento de qualquer negócio, modificando os meios de ligação com clientes e facilitando a realização de transações (Kalıpcı *et al.*, 2024).

A pandemia COVID-19 refletiu-se em impactos negativos em diversos setores, contudo, também possibilitou a expansão de outros. Em março de 2020, devido às políticas de isolamento, os consumidores tiveram de adaptar os seus hábitos de consumo e foram incentivados a encontrar soluções, levando os mesmo a investir no comércio digital (Nicewicz & Bilska, 2021; Kawasaki *et al.*, 2022 como citado Higuera-Castillo *et al.*, 2023). Esta adaptação por parte dos consumidores levou à crescente adoção de plataformas digitais de comércio, permitindo assim a expansão acelerada do setor de *E-commerce* (Shareef *et al.*, 2021; Modgil *et al.*, 2022 como citado em Higuera-Castillo *et al.*, 2023). Numa investigação acerca das vendas de *E-commerce*, Ramos *et al.* (2024) destacam que entre novembro e dezembro de 2020, as vendas registaram o seu pico mais elevado, sendo que, as oscilações registadas numa fase seguinte foram semelhantes a valores em anos anteriores, prevendo que a tendência de crescimento do setor se mantenha nos próximos anos.

As investigações acerca do *E-commerce* têm vindo a ganhar visibilidade devido à sua relevância e inovação, uma vez que, diversas empresas e áreas de negócio, recorrem a plataformas de comércio eletrónico para alcançar os seus clientes e os seus recursos, impulsionando uma tendência entre os negócios e o *E-commerce*. Kalıpcı *et al.* (2024) destacam, que esta dependência pode influenciar as estratégias e escolhas das organizações, realçando, novamente, o impacto que o comércio eletrónico tem nos novos modelos de negócios, afetando diretamente as suas operações.

Este tipo de comércio tem crescido exponencialmente nos últimos anos, uma consequência direta da adoção deste método por cada vez mais consumidores, por ser um método prático e facilmente acessível. Tendo em consideração estes fatores, autores como Ramos *et al.* (2024) e Kalıpcı *et al.* (2024) defendem que o *E-commerce* deverá continuar a crescer e, a alterar o panorama do comércio retalhista, em resultado não só da sua popularidade, como também do crescimento das acessibilidades resultantes dos dispositivos móveis e dos métodos de pagamento digitais. Kalıpcı *et al.*, (2024) terminam a sua investigação com algumas reflexões, sendo uma delas sobre a importância de investir em capacidades de *E-commerce* e em estratégias para aproveitar estas plataformas da melhor forma. Deste modo, considera-se pertinente a análise de oportunidades de investimento neste setor, em particular através do estudo e da previsão de ETF especializados em empresas focadas no *E-commerce*, como será desenvolvido nesta

investigação, possibilitando aos investidores acompanhar a evolução e capitalizar as oportunidades deste setor.

Contudo, apesar dos vários fatores que beneficiam a expansão deste setor, há ainda obstáculos a ultrapassar na capacidade de criação da intenção de compra online. Em 2003, o autor A. Pavlou destacou que o sucesso do comércio eletrônico na vertente B2C dependia não só, da aceitação das tecnologias e da Internet como meio de transação, mas também do reconhecimento dos retalhistas online como comerciantes fiáveis. O autor indicava a confiança e o risco percebido como os dois fatores determinantes, nos quais os retalhistas online se deviam focar e priorizar, de modo a reduzir a incerteza e aumentar a aceitação do *E-commerce*. 20 anos depois Higuera-Castillo *et al.* (2023) realizaram uma investigação acerca dos perfis de utilizadores espanhóis e portugueses em relação à adoção do *E-commerce* e o seu comportamento perante o comércio tradicional, nos quais é possível identificar que, apesar da evolução deste setor, as melhorias no mesmo são ainda necessárias, alinhando-se com alguma das conclusões de A. Pavlou (2003).

Na sua investigação, os autores Higuera-Castillo *et al.* (2023) conseguiram identificar características relevantes de compradores com maior tendência para recorrerem ao comércio online, tal como, ao comércio tradicional. Na ótica do comércio digital, destacam, como os fatores que mais influenciam os consumidores espanhóis, a tendência de repetir comportamentos de forma automática, a credibilidade e confiança, e a expectativa de esforço, ou seja, a facilidade subjacente à utilização deste tipo de comércio. Analisando o comportamento dos consumidores portugueses, os investigadores destacam fatores como: a confiança, sendo esta o fator mais relevante para esta população; as condições facilitadoras da utilização de plataformas de *E-commerce*; a influência social, ou seja, a perceção de que outras pessoas influentes utilizam este tipo de comércio e que o recomendam; e, por fim, o hábito. Em relação aos entraves os investigadores destacam como principais barreiras à adoção do *E-commerce*, o custo de mudança, o risco percebido, a privacidade, a tecnofobia e o género.

Considerando as limitações e as oportunidades do comércio eletrônico, torna-se relevante analisar, de que forma os investidores podem posicionar-se de forma estratégica neste setor, e beneficiar deste crescimento, nomeadamente através de instrumentos financeiros como os *Exchange Traded Funds* (ETF).

## **2.2. A Evolução e Relevância dos *Exchange Traded Funds* no Mercado Financeiro**

Segundo autores, como Atilgan *et al.* (2024), Joshi e Kumar Dash (2024) e Fonseca (2012) os ETF têm vindo a assumir, cada vez mais, um papel importante no Mercado Financeiro, dominando o cenário global de investimentos. Estes ativos tornaram-se numa das inovações financeiras mais bem-sucedidas, cativando, não só os investidores, como também os investigadores na área, sendo este um tópico que tem

crescido significativamente nos últimos anos. Joshi e Kumar Dash (2024), através da sua revisão bibliométrica com foco nos ETF e no futuro dos investimentos de gestão passiva, concluem que estes ativos são um produto financeiro essencial com um papel importante em diferentes contextos financeiros, acrescentando que, apesar de ser um tema muito desenvolvido e estudado, o número de publicações tem vindo a aumentar, especialmente entre 2020 e 2022, evidenciando a relevância e o potencial dos mesmos.

De acordo com, *The 2024 J.P. Morgan 2024 Global ETF Handbook* (Kolanovic e Kaplan; 2024), 20ª edição anual, o relatório do mercado global de ETF, estes produtos financeiros permitem aos investidores, através da negociação de um único ativo, a possibilidade de alcançarem a exposição a um vasto mercado de ações ou índices de referência, podendo deste modo, o investidor optar por uma maior diversificação do seu portfólio, ou focar-se num único setor, como o *E-commerce*. Segundo os mesmos, até maio de 2024, o mercado global de ETF estava avaliado em 13 mil milhões de dólares, sendo que, em comparação com o ano anterior, houve um crescimento de cerca de 10.1 mil milhões de dólares. Os autores Kolanovic e Kaplan (2024) destacam que, entre 2001 e 2011, o número de ETF listados a nível global, registava uma taxa média de crescimento anual de, aproximadamente, 30%. Porém, atualmente, com o amadurecimento do Mercado financeiro, a taxa média de crescimento anual é cerca de 10%. Contudo, apesar desta redução na taxa de crescimento, entre 2023 e 2024, foram registados mais 12 mil ETF globalmente, evidenciando a contínua expansão deste mercado e a dimensão do mesmo.

Entre 1980 e 1990, no Canadá, foi transacionado em bolsa o primeiro ETF, conhecido como *TSE 35 participation units*. Nos Estados Unidos, o primeiro ETF foi lançado em 1993, o *SPDR S&P 500 ETF (SPY)*, produto este presente na carteira de muitos investidores, atualmente. Posteriormente seguiu-se a Ásia, com o aparecimento do primeiro ETF em 1999 e, na Europa, em 2000, aproximadamente 10 anos após o primeiro ETF transacionado em bolsa (Joshi e Kumar Dash, 2024). No entanto, como qualquer outro produto financeiro, o reconhecimento e destaque dos ETF no mercado financeiro não foi imediato, uma vez que foi necessário que os investidores compreendem-se as características deste ativo e os seus benefícios de modo a reconhecer as suas vantagens (Joshi e Kumar Dash, 2024).

A crise financeira de 2008 teve um grande contributo na expansão dos ETF, afirmam os autores Joshi e Kumar Dash (2024). Devido à queda dos mercados, muitas pessoas sofreram perdas significativas, levando-os a procurar outras soluções para a recuperação desses investimentos, tais como, os ETF, produtos que oferecem um menor custo de manutenção e uma maior transparência. A partir deste momento registou-se uma alteração na dinâmica dos mercados desenvolvidos, onde os investimentos diretos em ações e fundos mútuos diminuíram, enquanto que, os ETF ganhavam mais quota de mercado (Joshi e Kumar Dash, 2024).

Em relação à natureza destes instrumentos financeiros, a autora Fonseca (2012) destaca que apesar dos mesmos serem negociados em bolsa diferenciam-se dos fundos de investimentos tradicionais,

surgem como uma alternativa aos mesmos, acrescentando novas funcionalidades e uma nova dinâmica ao Mercado Financeiro. Devido à sua estrutura de sociedades de investimento *open-end* de negociação contínua, possibilitam a emissão e resgate de ações, proporcionando aos investidores uma elevada liquidez, flexibilidade e baixos custos de transação (Atilgan *et al.*, 2024; Lettau & Madhavan, 2018). Segundo Fonseca (2012), Joshi e Kumar Dash (2024) os ETF destacam-se por serem uma alternativa mais flexível e acessível para os investidores. Cada unidade destes instrumentos oferece uma liquidez diária, tal como negociação e precificação contínua em tempo real (Kolanovic e Kaplan, 2024). Todas estas características têm impulsionado positivamente a popularidade destes ativos entre investidores e investigadores.

Compreendida a relevância e a versatilidade destes instrumentos de investimento, importa agora compreender de que forma é que estes têm sido aplicados a setores específicos, cuja expansão e transformação digital, os tornam particularmente atrativos, em termos de rentabilidade e diversificação, tal como o *E-commerce*.

### **2.3. Exchange Traded Funds no setor de E-commerce: Potencial de Investimento**

Os ETF associados à economia digital, reúnem ações de empresas que dependem da tecnologia digital e/ou vendem produtos digitais (Hoque *et al.*, 2024). Neste contexto, os ETF do setor de *E-commerce*, integram-se nesta categoria, refletindo o desempenho de empresas fortemente ligadas ao comércio eletrónico.

Segundo Simsek (2023a, 2013b) e Cong, Huang, and Xu (2024) citados em Atilgan *et al.* (2024), os investidores interessados em aspetos específicos de mercado, são cativados por instrumentos financeiros como os ETF, uma vez que os mesmos retêm uma maior eficiência informativa, e refletem de forma mais precisa, o desempenho do setor. Estas características devem-se ao facto de incorporarem nos seus preços de mercado informações características de cada setor, como por exemplo, no caso em estudo, os padrões do comércio eletrónico. Os autores acrescentam ainda que, os ETF são uma classe de ativos que permitem compreender o impacto das perceções do mercado em relação à digitalização. Neste sentido, os movimentos dos seus preços são altamente dependentes das perceções do mercado e dos avanços tecnológicos (Hoque *et al.*, 2024). Esta dependência é complementada pela relação entre a economia digital e o desempenho destes ETF, como realçado por Hoque *et al.* (2024). O autor conclui que à medida que a economia se adapta à transformação digital, e a estes ativos digitais, o interesse dos investidores nestes fundos continua a aumentar, demonstrando mais uma vez, o potencial significativo de ETF associados à digitalização (Kotarba, 2018 citado por Hoque *et al.*, 2024).

Através da literatura disponível, sobre os ETF e o comércio eletrónico, é possível destacar-se o interesse pela investigação de ETF em setores específicos, uma vez que os mesmos podem não só captar

informações sobre o potencial de crescimento do setor, como também contribuir para a formação de expectativas de mercado. Por conseguinte, a análise de ETF focados no setor do *E-commerce* permitirá compreender melhor o potencial de investimento associado a estes ativos e a este setor. Contudo, embora haja um número crescente de estudos sobre a previsão de ETF, destaca-se a falta de investigações acerca da previsão dos mesmos em setores específicos. Havendo conseqüentemente uma falta de estudos sobre quais as metodologias, e métodos de previsão de séries temporais, mais adequados para aplicar a ETF em setores específicos e dinâmicos.

Contextualizada a relevância destes ativos setoriais e a sua relação com a economia e transformação digital, é necessário explorar que tipo de técnicas e metodologias apresentam bons desempenhos preditivos no contexto de séries temporais financeiras.

#### **2.4. Previsão de séries temporais no contexto do Mercado Financeiro**

Os Mercados Financeiros, desempenham um papel importante no sistema financeiro, refletindo o estado da economia e as tendências de desenvolvimento. Através deste Mercado, as empresas conseguem adquirir capital, enquanto que os investidores têm a oportunidade de participar no crescimento e desenvolvimento das empresas (Bao *et al.*, 2025). No entanto, apesar da relevância dos mercados financeiros, o seu elevado grau de incerteza e complexidade, representam um grande desafio na previsão do seu comportamento (Najem, Bahnasse, *et al.*, 2024).

Em 1960, o Professor Eugene F. Fama, da Universidade de Chicago, introduziu um conceito fundamental na teoria dos mercados financeiros, a *Efficient Market Hypothesis* (EMH), formalizada em 1970 (Fama, 1970 como citado em Bao *et al.*, 2025). Esta Hipótese, juntamente com a *Random Walk Hypothesis* (Fama, 1995 como citado em Beniwal *et al.*, 2024) defendem que os preços do mercado refletem toda a informação disponível, seja esta pública ou privada, o que limita significativamente a possibilidade de prever com precisão os movimentos do mercado (Bao *et al.*, 2025; Beniwal *et al.*, 2024). Por esta razão, as flutuações dos preços são influenciadas não só pelo desempenho das empresas, mas também devido a fatores como políticas económicas, desenvolvimento industrial, notícias e as decisões e opiniões de investidores. Qualquer alteração nestes fatores é refletida de forma imediata no valor dos produtos financeiros, demonstrando a imprevisibilidade do seu valor e o desafio dos investidores (Bao *et al.*, 2025; Beniwal *et al.*, 2024; Zhao *et al.*, 2023).

Além deste desafio, devido à natureza das séries temporais os dados gerados por estes ativos, sejam ETF ou ações, apresentam características desafiantes para as ferramentas de *forecasting*, tal como a sua não linearidade, irregularidade e comportamento estocástico (Zhao *et al.*, 2023). Tendo em consideração estas limitações, a procura por soluções de previsão, que possibilitem aos investidores ultrapassar os retornos médios do mercado, tem vindo a ganhar cada vez mais destaque e, a incentivar

investigadores e analistas financeiros a desenvolverem novos métodos de previsão (Bao *et al.*, 2025; Zhao *et al.*, 2023).

Entre os tópicos mais estudados na previsão de séries financeiras, aquele que mais se destaca, é a previsão de preços de ativos, onde o principal foco é prever o próximo movimento do ativo num horizonte de curto prazo (Sezer *et al.*, 2020). Com base na revisão sistemática de literatura do Autor Sezer *et al.* (2020) observa-se que, entre o total de artigos analisados, cerca de quarenta e seis, a maioria, abordam o tema de *stock price forecasting*, enquanto os temas de *volatility forecasting* e *cryptocurrency price prediction*, demonstram ser os menos destacados, até à data, na área de previsão de séries temporais.

O Autor Zhao *et al.* (2023), citando Agustini *et al.* (2018), Jing *et al.* (2022) e Zhang *et al.* (2021), define a previsão de preço de mercado como o objetivo de antecipar as tendências futuras com base em dados históricos, referindo que esta solução permite aos investidores compreender o funcionamento do mercado e tomar decisões mais informadas, reduzindo o risco associado às mesma e aumentando os seus retornos. Garg *et al.* (2022) e Zhao *et al.* (2023) corroboram com esta definição, mas destacam que, a análise exploratória das séries é um passo crucial para a eficácia da previsão e, para a robustez e eficiência dos modelos preditivo.

Outros fatores importantes a considerar na previsão de séries temporais, é o horizonte temporal e a frequência da previsão. A frequência da previsão pode ser anual, mensal, diária, ou horária, sendo que, cada uma destas frequências apresenta diferentes características e desafios. Deste modo, para definir-se qual a periodicidade mais adequada, cada analista deve considerar a o âmbito de aplicação dos resultados que serão obtidos (Garg *et al.*, 2022). Adicionalmente é importante compreender que quando se analisam previsões com diferentes horizontes temporais, é geralmente mais expectável que as previsões de curto prazo sejam mais fiáveis, devido à menor incerteza associada às mesmas (Garg *et al.*, 2022).

Em relação às diferentes abordagens de previsão do preço de ações, Beniwal *et al.* (2024) e Vijh *et al.* (2020), destacam duas abordagens principais: a análise técnica, que se concentra na observação de padrões e tendências nos dados históricos e, a análise qualitativa, que considera fatores externos ou internos que possam impactar diretamente o setor da empresa ou a própria empresa. Com foco na análise técnica, destacam-se os métodos *data-driven*, tais como, modelos Matemáticos de análise de séries temporais e, métodos de *Machine Learning* (ML) e *Deep Learning* (DL) (Zhao *et al.*, 2023). Através de informação histórica, dados quantitativos e/ou qualitativos, estes métodos são capazes de identificar padrões e fazer previsões acerca das oscilações nos preços de mercado (Bao *et al.*, 2025; Zhao *et al.*, 2023; Vijh *et al.*, 2020). O autor Ramos (2021) sustenta a afirmação anterior, realçando a importância de apoiar a tomada de decisão, com a conjugação de técnicas baseadas em métodos estatísticos e computacionais na modelação de séries temporais.

Diversas investigações no domínio da previsão de séries temporais, com foco no setor financeiro, (Ramos *et al.*, 2024; Zhao *et al.*, 2023; Ramos *et al.*, 2023; Pratas *et al.*, 2023; Bansal *et al.*, 2022; Vijh *et al.*, 2020; Kumar *et al.*, 2022) discutem a utilização de métodos clássicos, bem como técnicas de ML e DL, analisando os benefícios e limitações de cada uma. Sendo que, muitos estudos recentes destacam o crescente potencial de Metodologias baseadas em DL como alternativa às abordagens convencionais (Ramos *et al.*, 2023; Pratas *et al.*, 2023; Ramos, 2021; Ramos *et al.*, 2024; Tealab, 2018; Zhang *et al.*, 1998).

Em suma, como mencionado por Hang (2019) citado em Ramos *et al.* (2024), em qualquer setor, as ferramentas de *forecasting* são fundamentais para um bom planeamento e para uma gestão eficiente dos recursos, tornando-se evidente que, os desenvolvimentos nas técnicas de previsão desempenham um papel cada vez mais relevante na otimização de processos e na maximização de resultados. Assim, torna-se pertinente compreender as principais metodologias de previsão, começando pelas abordagens clássicas e evoluindo para as técnicas de ML e DL.

#### **2.4.1. Metodologias clássicas de previsão de séries temporais**

Os métodos estatísticos, também mencionados como Clássicos, foram os primeiros métodos a fornecer uma base teórica e prática para a previsão de séries temporais (Bao *et al.*, 2025; Zhao *et al.*, 2023). Os principais modelos inseridos nesta categoria, são os modelos da família ARMA, que apesar de terem surgido em 1970, são aplicados até aos dias de hoje, e fornecem previsões razoavelmente precisas a um baixo custo computacional, permitindo uma boa compreensão dos resultados e uma fácil aplicação (Ramos, 2021; Ramos *et al.*, 2024). Com todas estas vantagens, destacam-se também outras metodologias clássicas, sendo os modelos de Alisamento Exponencial (ES), uma das recomendadas pela literatura, no âmbito de séries financeiras (Ramos, 2021; Wilson *et al.*, 2020).

O modelo ARMA é um modelo linear de previsão de séries temporais, evidenciado pela sua boa performance e pela sua capacidade de estimar séries temporais com comportamentos irregulares suaves. Porém, devido ao comportamento não linear das séries temporais dos mercados financeiros, os autores Zhao *et al.* (2023) e Bansal *et al.*, (2022), propõe a utilização do modelo ARIMA, o modelo Autorregressivo de Médias Móveis desenvolvido por George Box e Gwilym Jenkins em 1970 (Garg *et al.*, 2022). Este modelo detém de todas as vantagens do modelo ARMA, e comata algumas das suas desvantagens devido à sua capacidade de lidar com séries não estacionárias, sendo uma das técnicas mais utilizadas no contexto da previsão de séries temporais, inclusive na previsão de preços de mercado (Bansal *et al.*, 2022; Vijh *et al.*, 2020; Kumar *et al.*, 2022; Garg *et al.*, 2022). Atualmente, existem múltiplos modelos desenvolvidos com base no modelo ARIMA, criados com o objetivo de responder às diferentes

necessidades da previsão de séries temporais, reforçando a sua versatilidade e capacidade preditiva (Garg *et al.*, 2022).

Os modelos ES, desenvolvidos por Brown e Holt, são uma abordagem clássica aplicada e reconhecida na previsão no contexto das finanças, da economia, da gestão de operações e da saúde. A sua relevância no âmbito desta investigação deve-se, tal como o modelo ARIMA, à simplicidade de implementação, ao baixo custo computacional e aos resultados geralmente satisfatórios, características prioritárias em ambientes empresariais onde a rapidez na tomada de decisão é essencial (Ramos, 2021; Wilson *et al.*, 2020). Como mencionado pelo autor Ramos (2021), as previsões destes modelos atribuem um maior peso aos dados mais recentes das séries, ou seja, aos acontecimentos mais atuais do horizonte temporal em análise, constituindo médias ponderadas observadas, e permitindo suavizar as flutuações aleatórias da série, fornecendo uma maior estabilidade.

Contudo, o ARIMA e os ES também apresenta algumas desvantagens, como a dificuldade de lidar com séries cuja variância não é constante, uma das características presentes em várias séries temporais dos mercados financeiros, devido à volatilidade de alguns preços de mercado (Bansal *et al.*, 2022). Devido a esta limitação poderá ser possível observar em alguns casos o denominado efeito ARCH nos resíduos dos modelos, levando à introdução do modelo GARCH, o modelo de heterocedasticidade condicional autorregressiva generalizada. Este modelo foi desenvolvido com o intuito de prever e modelar a volatilidade de séries temporais cuja variância não seja constante, sendo ainda capaz de lidar com séries não estacionárias, representando melhor a tendência dos preços nos mercados financeiros (Zhao *et al.*, 2023; Dudek *et al.*, 2024).

Apesar dos benefícios da aplicação dos métodos clássicos, estas Metodologias enfrentam algumas limitações quando aplicadas a dinâmicas reais de mercado. A principal limitação apontada por Bhandari *et al.* (2024) é a suposição de relações lineares entre as variáveis o que, segundo o autor, levanta preocupações quanto à robustez destes modelos, uma vez que, diversas séries temporais, especialmente em contextos financeiros, apresentam comportamentos complexos e não lineares.

Existem ainda outras características que podem levar a complicações na fase de modelação e previsão, como a crescente evolução dos mercados, impulsionada pela digitalização, o que poderá refletir-se em maus desempenhos dos modelos, mas também, impulsionar o desenvolvimento de outras soluções que capazes acompanhar esta evolução (Chatfield, 2016 como citado em Ramos *et al.*, 2023; Bao *et al.*, 2025).

#### **2.4.2. Metodologias *Machine Learning* de previsão de séries temporais**

Devido às limitações dos métodos clássicos, a investigação científica tem sido direcionada para a aplicação de diversas técnicas de AI (Ramos, 2021), tais como, o *Machine Learning*. Atualmente, a maior

parte dos avanços na previsão de séries temporais devem-se à evolução dos métodos de Inteligência Artificial, resultando numa crescente adoção destas técnicas e no seu destaque na literatura (Cavalcante *et al.*, 2016). Os desenvolvimentos significativos na capacidade computacional, juntamente com a capacidade de estes modelos processarem de forma rápida e eficiente, grandes volumes de dados, incluindo dados não estacionários ou não lineares, tornou-os ferramentas de referência na previsão de preços de mercado (Bansal *et al.*, 2022; Bao *et al.*, 2025; Kumar *et al.*, 2022; Najem, Bahnasse, *et al.*, 2024; Song, 2018 citado em Zhao *et al.*, 2023).

As técnicas de ML podem ser divididas em dois métodos de aprendizagem, a aprendizagem supervisionada e a não supervisionada. No âmbito da aprendizagem supervisionada, o objetivo é que o modelo seja treinado com o intuito de ao receber novos dados, consiga fazer uma previsão precisa, com base nos padrões aprendidos com os dados de *input*. Enquanto, na aprendizagem não supervisionada, o objetivo passa por construir um modelo, capaz de encontrar alguma similaridade e correlação nos dados de *input* (Bansal *et al.*, 2022).

Ao contrário dos métodos clássicos, os de ML não dependem de suposições prévias acerca da estrutura dos dados, ou seja, apresentam uma maior capacidade para processar dados não lineares, possibilitando a identificação de padrões dinâmicos e complexos, características presentes em séries temporais de preços de mercado (Bao *et al.*, 2025; Dudek *et al.*, 2024). Adicionalmente, estes modelos apresentam também melhores níveis de *performance* ao longo da fase de treino, evidenciado a sua flexibilidade e adaptabilidade em comparação com os modelos clássicos (Dudek *et al.*, 2024).

Considerando a literatura, a aplicação de algoritmos de ML no contexto de previsão de séries temporais tem se mostrado promissora, sendo acompanhada por um crescente número de publicações que evidenciam resultados superiores face às Metodologias Clássicas (Sezer *et al.*, 2020). Entre os diferentes modelos de ML utilizados na previsão de preços de mercado, aqueles que evidenciam uma melhor performance, segundo a literatura, são o *Support Vector Machine* (SVM), o *Support Vector Regression* (SVR) e o *Random Forest* (RF) (Beniwal *et al.*, 2024; Dudek *et al.*, 2024; Najem, Amr, *et al.*, 2024; Vijn *et al.*, 2020).

O RF executa a sua previsão combinando diferentes árvores de decisão onde, cada árvore reparte os dados de diferentes formas resultando em distintas funções de regressão. De seguida, de forma hierarquizada, estas funções são transformadas em regras de decisão, fáceis de interpretar e de aplicar ao contexto em análise (Dudek *et al.*, 2024; Najem *et al.*, 2024). O SVM, tal como o RF, é um modelo aplicado em problemas de classificação, que tem como objetivo, através do método de *Kernel trick*, encontrar a linha que melhor separa as duas classes (Najem, Amr, *et al.*, 2024).

Com base no SVM, foi desenvolvido o SVR, capaz de lidar com problemas de regressão (Dudek *et al.*, 2024; Najem, Amr, *et al.*, 2024). O SVR é atualmente uma ferramenta muito utilizada na

resolução de problemas de regressão, sendo reconhecido pela sua combinação de características que conjugam a simplicidade e a eficiência de algoritmos lineares com a precisão dos algoritmos não lineares (Dudek *et al.*, 2024).

Contudo, estes métodos mais avançados ainda apresentam algumas limitações. Segundo Bao *et al.* (2025) as principais limitações focam-se na incapacidade de extração automática das suas características, na dificuldade de generalização e na necessidade de parametrização manual, que no contexto de um mercado em constantes oscilações, dificulta a sua aplicação. Outro fator destacado por Dudek *et al.* (2024), é o desafio de otimizar estes modelos, uma vez que, certos hiperparâmetros, definidos no contexto dos dados de treino, muitas vezes não se generalizam à realidade do conjunto de teste ou validação. Além destas limitações, estas Metodologias podem nem sempre ser adequadas a todas as séries temporais como validado por Dudek *et al.* (2024).

### **2.4.3. Metodologias *Deep Learning* de previsão de séries temporais**

As ferramentas de *Deep Learning*, apresentam características cada vez mais promissoras, evidenciado uma capacidade superior em identificar padrões complexos, muitas vezes impercetíveis quando aplicadas abordagens tradicionais (Bhandari *et al.*, 2024; Garg *et al.*, 2022; Sezer *et al.*, 2020). Algumas das suas principais vantagens são a captura de dependências temporais, a adaptabilidade a diferentes condições de mercado e a gestão eficiente de grandes volumes de Dados, em tempo real. A conjugação destas características permite aos investidores tomarem decisões *data-driven*, mantendo-se competitivos num ambiente em constante evolução (AlMadany *et al.*, 2024).

Em comparação com os métodos de ML, atualmente, observa-se uma tendência crescente da aplicação desta metodologia (Bhandari *et al.*, 2024; Sezer *et al.*, 2020). Contudo, o Autor Sezer *et al.* (2020), acrescenta que, apesar de haver vários estudos a apontarem para a superioridade dos modelos DL em detrimento do ML, os resultados nem sempre são tão conclusivos. Em certos estudos, ambas as Metodologias evidenciam desempenhos muito idênticos, destacando a necessidade de efetuar-se uma escolha criteriosa baseada no problema em análise e nos dados disponíveis (Sezer *et al.*, 2020).

A transição dos métodos de ML para os métodos de DL foi impulsionada por diferentes fatores, entre os quais se destacam, o aumento do poder computacional, a crescente disponibilidade de grandes volumes de dados, os níveis de desempenho superiores e o acesso a ambientes *user-friendly* para o desenvolvimento de modelos de DL (Sezer *et al.*, 2020). Para além destes fatores, os modelos baseados em DL oferecem uma maior precisão e flexibilidade, embora exijam um maior tempo de treino e recursos computacionais capazes de suportarem o seu desenvolvimento (Garg *et al.*, 2022).

A principal característica dos modelos de DL, é a sua estrutura baseada em Redes Neurais, caracterizada pelas múltiplas camadas de processamento (Sezer *et al.*, 2020; Garg *et al.*, 2022). Por esta

razão, estes métodos aproximam-se do funcionamento de um cérebro humano, diferenciando-se assim das Metodologias de ML que, apesar dos avanços computacionais, necessitam de mais assistência técnica (Bansal *et al.*, 2022). Outra vantagem, reside na sua capacidade de extrair automaticamente características importantes nos dados, dispensando intervenções manuais complexas (Bhandari *et al.*, 2024; Sezer *et al.*, 2020). Conjugando todos estes benefícios, quando o objetivo se trata de modelar séries temporais com comportamentos irregulares e em contextos altamente dinâmicos, os modelos de DL têm vindo a destacar-se. (Zhao *et al.*, 2023; Sezer *et al.*, 2020).

O Autor Najem *et al.* (2024) define uma *Artificial Neural Network* (ANN) como um sistema de aprendizagem computacional que utiliza uma rede funcional, simulada através do conceito de rede de neurónios do cérebro humano, para interpretar os dados de *input* e convertê-los nos desejados *outputs*. Entre os diferentes tipos de Redes Neurais, as *Recurrent Neural Networks* (RNN), as *Multi-Layer Perceptrons* (MLP) e as *Long Short-Term Memory* (LSTM) estão entre as mais discutidas e utilizadas por investigadores (Bansal *et al.*, 2022; Dudek *et al.*, 2024; Garg *et al.*, 2022; Kumar *et al.*, 2022; Najem, Amr, *et al.*, 2024; Najem, Bahnasse, *et al.*, 2024; Sezer *et al.*, 2020; Vijn *et al.*, 2020; Zhao *et al.*, 2023).

No contexto de problemas de regressão, como *stock price forecasting*, as MLP são reconhecidas pelos seus bons resultados, obtidos através da combinação linear das funções de ativação nas *hidden layers*. Segundo Dudek *et al.* (2024) este tipo de redes destaca-se entre investigações devido à sua capacidade de aprendizagem, de modelação não linear e resistência ao ruído nas séries temporais.

As RNN surgem como uma evolução das redes *feedforward*, distinguindo-se pela sua capacidade de integrar mecanismos de *feedback* que possibilitam a criação de memória interna e o processamento de dados sequenciais (Beniwal *et al.*, 2024; Garg *et al.*, 2022). Simultaneamente, as RNN beneficiam da aptidão de processarem dados com características comuns de séries temporais, como a tendência, a sazonalidade e a não estacionaridade, através das conexões internas que estabelecem nas camadas ocultas, que possibilitam a extração de padrões e informações que outras redes não conseguiriam captar (Zhao *et al.*, 2023). No entanto, embora estes modelos, num contexto de memória de curto prazo, apresentem uma boa performance, a sua estrutura mostra-se limitadora a reter informações de longo prazo, uma vez que, tendem a perder rapidamente informações anteriores, e não conseguem de forma eficiente filtrar a informação relevante (Zhao *et al.*, 2023; Garg *et al.*, 2022; Sezer *et al.*, 2020).

De modo a ultrapassar algumas das limitações das RNN, surge, em 1997, a LSTM, a rede neuronal desenvolvida por Sepp Hochreiter e Jurgen Schmidhuberque (AlMadany *et al.*, 2024). As LSTM evidenciam uma maior capacidade de retenção de dependências de longo prazo, sem comprometer a captura de relações de curto prazo (Bhandari *et al.*, 2024; Garg *et al.*, 2022; Najem, Bahnasse, *et al.*, 2024; Sezer *et al.*, 2020). Este tipo de rede neuronal destaca-se pela sua arquitetura interna constituída por quatro componentes essenciais: a porta de entrada, a porta de saída, a porta de

esquecimento e a de memória (Beniwal *et al.*, 2024; Garg *et al.*, 2022; Sezer *et al.*, 2020). Devido a esta estrutura única possuem a capacidade de selecionar de forma dinâmica a informação que deve ser mantida ou descartada (Garg *et al.*, 2022), mitigando o problema de *vanishing gradient*, presente nas RNN (Beniwal *et al.*, 2024). O investigador Beniwal *et al.* (2024) afirma que, devido ao desempenho deste tipo de redes é possível observar-se que os preços das ações são fortemente influenciados pelos seus próprios históricos, e que a retenção eficaz desse contexto temporal contribui diretamente para a precisão das previsões (Beniwal *et al.*, 2024).

No entanto, apesar destas vantagens e da sua qualidade de previsão, é preciso compreender que, apesar de serem modelos avançados, os mesmos não são capazes de eliminar totalmente o risco (Najem, Bahnasse, *et al.*, 2024), sendo também necessário refletir sobre os custos computacionais substanciais desta estrutura (Ramos *et al.*, 2024; Zhao *et al.*, 2023; Pratas *et al.*, 2023; Ramos, 2021). Por fim, segundo Dudek *et al.* (2024), além de um maior tempo de processamento, devido ao conjunto de parâmetros superiores às outras metodologias, as técnicas de DL apresentam simultaneamente um desafio no processo de otimização.

## **2.5. Confronto de Evidências: Métodos de Previsão na Literatura Científica**

A previsão de preços de mercado, apesar de ser um área inserida no subconjunto de previsão de séries temporais, possui especificidades próprias, principalmente devido às expectativas de retorno financeiro subjacente (Sezer *et al.*, 2020). Ao longo das secções anteriores é possível compreender que, existem diferentes abordagens e ferramentas aplicadas no contexto da análise preditiva de preços de mercado, porém, o autor Sezer *et al.* (2020) realça que, modelos com uma maior precisão ou níveis de desempenho superiores, podem não estar associados a uma maior rentabilidade porque, bons resultados de previsão estão também associados a outros fatores, como o risco envolvido, os custos operacionais e, a dinâmica de mercado.

Neste contexto, é essencial compreender de que forma os diferentes métodos se posicionam, quando considerado o seu desempenho e aplicabilidade. Consequentemente, nesta secção é realizada uma análise comparativa sobre as diferentes conclusões obtidas pelos autores, com o intuito de compreender quais as principais evidências, complementaridades e limitações dos diferentes métodos utilizados.

Najem, Bahnasse, *et al.* (2024) defendem que, a incorporação de técnicas de AI em estratégias de análise e previsão financeira, tem o potencial de gerar melhores resultados, não só a nível de desempenho, mas também de retornos. Esta conclusão é suportada por Zhao *et al.* (2023), demonstrando no seu estudo, que entre os diferentes métodos de *stock price forecasting*, os métodos de DL são os que apresentam métricas mais positivas quando comparados com os métodos clássicos e métodos simples de ML. Contudo, realça uma limitação destes métodos que deve ser considerada na sua aplicação, o risco de

*overfitting*. A boa performance dos modelos de AI, está fortemente relacionada com os seus parâmetros, essencialmente com a taxa de aprendizagem, porém quanto maior for este parâmetro, maior a probabilidade de *overfitting*, resultando numa menor adequação dos modelos DL a dados fora da amostra de treino (Najem, Bahnasse, et al., 2024).

Beniwal *et al.* (2024), com o objetivo de analisar o comportamento de diferentes modelos de DL no contexto da previsão de preços a longo prazo, obteve conclusões similares a Najem, Bahnasse, *et al.* (2024) e Zhao *et al.* (2023). Na performance dos modelos, a LSTM revelou-se a mais eficaz e, curiosamente, apesar de apresentar um desempenho inferior na fase de treino, na amostra de teste evidenciou um resultado mais robusto, levando o autor a concluir que estes modelos têm uma capacidade de generalização maior, em contexto de previsão de longo prazo (Beniwal *et al.*, 2024). Adicionalmente, o seu estudo demonstrou que o desempenho dos modelos preditivos pode também ser afetado de acordo com o índice analisado, sugerindo que dinâmicas de mercado variam consoante as diferentes regiões demográficas.

Ao contrário dos anteriores autores, Bansal *et al.* (2022) pretende, com a sua investigação, confrontar a capacidade de previsão de cinco diferentes algoritmos, o *Linear Regression* (LR), o SVR, o *Decision Tree Regressor* (DTR), e a LSTM. Analisando as métricas de avaliação, à semelhança de Beniwal *et al.* (2024), Najem, Bahnasse, *et al.* (2024) e Zhao *et al.* (2023), os autores concluem que a LSTM desempenhou a melhor previsão, mas com a segunda melhor performance destaca-se o algoritmo SVR, um modelo de ML. As conclusões de Bansal *et al.* (2022), são reforçadas por Vijh *et al.* (2020), que após um estudo acerca da previsão de preços de mercado utilizando métodos de ML, constatou, através de uma análise comparativa de métricas de avaliação, que as *Artificial Neural Networks* apresentaram a melhor performance, seguindo-se o modelo RF com uma *performance* igualmente positiva e níveis de erro muito próximos.

Os autores AlMadany *et al.* (2024) e Dudek *et al.* (2024), desenvolveram investigações semelhantes na área de previsão de retornos de *cryptocurrency*, contudo, apesar de objetivos semelhantes, ambos deparam-se com resultados divergentes. AlMadany *et al.* (2024) concluíram com o seu estudo, que tanto o modelo ARIMA, como a LSTM, registam boas previsões deste tipo de ativos. Porém, ao contrário de AlMadany *et al.* (2024), Dudek *et al.* (2024) mostram-se desapontados com os resultados obtidos na sua investigação, uma vez que, entre os diferentes modelos aplicados a LSTM não apresentou bons resultados quando comparada com outros métodos de ML e Clássicos.

Com este contraste de resultados, observa-se que nem sempre os modelos mais avançados apresentam os melhores resultados. Em certos contextos de mercado, é possível que os métodos clássicos consigam sobrepor-se em termos de *performance*, de custo computacional e de aplicabilidade.

Em suma, Zhao *et al.* (2023) e Beniwal *et al.* (2024) convergem na conclusão de que as redes LSTM apresentam o melhor desempenho, sendo, assim recomendadas como uma das abordagens adequadas a aplicar ao contexto de previsão de preços de mercado, especificamente em contextos de longo prazo. Por sua vez, Bansal *et al.* (2022) e Vijn *et al.* (2020), apesar de obterem resultados semelhantes, refletem acerca dos custos computacionais associados aos modelos de DL, questionando a relação custo-benefício da sua aplicação face a outras opções como o RF ou o SVR, que nos estudos em questão demonstraram níveis de performance muito competitivos. Por fim, AlMadany *et al.* (2024) e Dudek *et al.* (2024), apesar de diferentes conclusões, ambos destacam a capacidade preditiva dos modelos preditivos clássicos, que num contexto de mercado, muito volátil e imprevisível, é capaz de obter boas previsões e até mesmo superar os modelos DL.

### 3. Metodologia

A metodologia aplicada nesta investigação é baseada no CRISP-DM, dividindo-se nas seguintes fases: a compreensão do negócio e dos dados, a preparação dos dados, a modelação, a avaliação do modelo e, por fim, a comparação dos modelos. O reconhecimento desta metodologia, no meio científico e académico, facilita a aplicação estruturada das fases de investigação e permite uma melhor compreensão (Schröer *et al.*, 2021). Adicionalmente, para uma melhor compreensão dos modelos e da sua aplicação ao âmbito da investigação, considerou-se duas referências principais: o livro de Brownlee (2018) e a investigação de Ramos (2021), que serviram de base para o desenvolvimento da abordagem metodológica implementada neste estudo.

#### 3.1. Compreensão do negócio

A fase de compreensão de negócio teve início durante a revisão de literatura, apresentada na secção 2., onde se destacou a oportunidade de investigação no domínio de ETF em setores específicos, com especial enfoque no setor de comércio eletrónico. Esta revisão permitiu fundamentar a relevância do tema, bem como a lacuna na investigação e a pertinência da aplicação de ferramentas de *Business Analytics* neste contexto.

#### 3.2. Compreensão dos dados

##### 3.2.1. Bases de dados

Compreendido o âmbito desta investigação procedeu-se à seleção e à extração dos dados históricos de cada ETF. Para a seleção dos dados procedeu-se à análise dos diferentes ETF inseridos no setor do comércio eletrónico, procurando compreender os que se destacavam e quais os mais adequados aos objetivos desta investigação. Deste modo, foram selecionados os seguintes ETF:

- Amplify Online Retail ETF (IBUY): Constituído em abril de 2016 e gerido pela Amplify Investments LLC, este ETF procura replicar o desempenho do EQM Online Retail Index. Investe em ações de empresas globais que operam no setor de comércio online, incluindo Wayfair, Lyft, Carvana, DoorDash, Chewy, Etsy, Amazon, Uber e eBay. A distribuição geográfica deste produto é concentrada nos EUA (76.28%), seguindo-se a China (7.04%) e o Japão (3.4%). Em termos de setores este Fundo é mais impactado por empresas de retalho e de *marketplaces*.
- Global X E-commerce ETF (EBIZ): É um ativo que procura capitalizar a tendência do comércio eletrónico, investindo em empresas que estejam posicionadas de modo a beneficiar da expansão deste setor. Entre os seus top *holdings* destacam-se empresas como Alibaba, Shopify, eBay, Etsy, Carvana, Sea Ltd, Mercado Libre e NetEase. Este ETF tem uma maior exposição no setor de

bens de consumo discricionário (65.6%), com uma forte presença de empresas dos EUA (41.7%) e da China (26.6%).

- ProShares Online Retail ETF (ONLN): Este fundo visa replicar o desempenho do ProShares Online Retail Index, focando-se em empresas cotadas nos EUA que são caracterizadas como retalhistas online. Apresenta uma forte concentração de empresas dos EUA (76%), seguindo-se a China com uma representatividade de 10.6%. As empresas que mais se destacam neste fundo são a Amazon (23.9%), o Alibaba (8.37%) e o eBay (7.24%).

Feita a seleção e contextualização destes ETF, procedeu-se à recolha dos respetivos dados históricos, com o objetivo de compreender a sua evolução e comportamento ao longo do tempo. Através do *Yahoo Finance* e, da biblioteca *yfinance* do *Python*, foi possível extrair diversos dados históricos, como o preço de fecho e de abertura (*Closing* e *Open Price*), o volume transacionado (*Volume*), o máximo diário (*High*) e o mínimo diário (*Low*). Contudo, de modo a alcançar o objetivo de investigação esta análise concentrou-se na análise da variável *Closing Price* de cada ETF.

O horizonte temporal definido abrange o período de janeiro de 2019 a abril de 2025 e, tendo em consideração o âmbito da investigação, optou-se por uma periodicidade diária onde são analisados um total de 1590 *trading days*, o que corresponde, aproximadamente, a um horizonte temporal de 5 anos. Esta escolha temporal teve como objetivo analisar o comportamento da série durante eventos impactantes no setor, como a pandemia COVID-19, o desconfinamento e o processo regulamentar de aumento das tarifas ao comércio nos Estados Unidos da América (EUA).

### **3.2.2. Verificação da qualidade dos Dados**

Com o objetivo de validar a integridade e adequação dos Dados, procedeu-se à validação da qualidade dos mesmos, assegurando a completude e fiabilidade da informação recolhida, e conseqüentemente, a robustez desta investigação. Dada a natureza dos dados e o método de extração, é expectável não se registarem valores omissos ou duplicados, mas realizou-se uma verificação dos mesmos, onde se apurou a ausência de ambos.

Em relação à verificação e tratamento de *outliers*, no âmbito de séries temporais financeiras, é expectável a evidência de valores extremos, porém os mesmos são relevantes para a investigação e para a previsão de dados futuros, sendo que representam frequentemente variações genuínas associadas à dinâmica do mercado, pelo que a sua preservação é essencial para manter a integridade da informação e garantir previsões mais realistas.

### 3.2.3. Descrição e exploração dos Dados

A análise exploratória das séries temporais, é um passo fundamental neste estudo e essencial para o processo de modelação das séries temporais. Com esta análise pretende-se compreender o comportamento destes três ETF de *E-commerce*, recorrendo a estatísticas descritivas e à análise inferencial, como testes de independência e de normalidade. Esta análise será ainda complementada com recurso a visualizações gráficas que possibilitem a interpretação das oscilações ao longo do tempo, e dos impactos dos eventos extremos nas diferentes séries.

Outro passo importante na exploração de séries temporais é a decomposição das séries para verificar se as mesmas apresentam aleatoriedade, tendência, estacionaridade e/ou sazonalidade (Pratas, 2022; Ramos, 2021), uma vez que, estas características impactam a seleção e a parametrização dos modelos. Considerando o objetivo desta investigação foram analisadas estas características com recurso a visualizações gráficas, como por exemplo, o *boxplot* e gráficos de linhas, permitindo analisar-se a evolução das séries e a presença de padrões de sazonalidade ou tendência. Para validar as conclusões obtidas acerca da estacionaridade das séries, foram aplicados os testes *Augmented Dickey-Fuller* (ADF) e *Kwiatkowski-Phillips-Schmidt-Shin* (KPSS).

Compreendido o comportamento evolutivo das séries e as suas características, procedeu-se à implementação de uma análise de risco simples, que permite a investigadores e investidores retirar *insights* sobre o risco associado a estes ativos, e compreender qual o ativo que maximiza a relação entre o risco e o retorno. Esta análise foi desenvolvida com base em métricas como a Volatilidade Anualizada, o *Sharpe Ratio*, a *Skewness*, a *Kurtosis* e outras medidas de risco, associadas à perda esperada, como o *Value at Risk* (VaR) e o *Expected Shortfall* (ES).

- O *Sharpe Ratio* permite avaliar o desempenho ajustado ao risco, ou seja, quanto maior, melhor o retorno obtido por cada unidade de risco assumido;
- O VaR estima a perda máxima esperada num determinado horizonte temporal, para um nível de confiança de 95%, no âmbito deste estudo;
- O ES é uma medida complementar ao VaR, que estima a perda média esperada quando as perdas excedem o valor indicado pelo VaR.

A incorporação desta análise de risco permite a inclusão de uma perspetiva quantitativa do risco, complementando a análise exploratória e contribuindo para uma caracterização mais robusta das séries na ótica de investimentos. Compilando estas duas análises será possível responder à primeira questão de investigação, através da análise aprofundada do comportamento das séries temporais dos três ETF de *E-commerce* em estudo.

### 3.3. Preparação dos Dados

Numa fase inicial, de exploração dos dados, não foi necessário a aplicação de tratamentos robustos aos mesmo, uma vez que, se trata de dados já estruturados e que não apresentavam incidências na fase de controlo de qualidade. Contudo, para a análise de risco, descrita na secção 3.2., foi necessário proceder-se à transformação da variável *Closing Price*. Esta transformação baseou-se na logaritmação da diferença entre os *Closing Price* de dias consecutivos, dando assim origem a uma nova variável, os retornos logarítmicos.

Na fase de modelação das séries temporais, apenas no caso dos modelos de ML, foi necessário proceder-se a transformações nas séries temporais, de modo a enquadrarem-se num problema de aprendizagem supervisionada, onde cada amostra é composta por um input ( $X$ ) e um output ( $y$ ). Para esta transformação recorreu-se à aplicação da técnica de janelas deslizantes (*sliding windows* ou método de *lags*), onde são criadas as variáveis explicativas através dos valores registados em momentos anteriores (Brownlee, 2018). Considerando o objetivo desta investigação e a necessidade de os modelos captarem padrões de curto prazo, definiram-se duas janelas temporais, uma de 1 dia e outra de 5 dias, com o intuito de testar qual proporcionaria o melhor desempenho.

Obtêm-se assim séries temporais transformadas em conjuntos de pares  $(X,y)$ , onde cada  $X$ , representa uma sequência de 1 ou 5 observações passadas, e  $y$  corresponde ao valor seguinte (ex:  $X=1,2,3,4,5$  ;  $y = 6$ ). Através desta transformação os modelos de ML procuram aprender a dinâmica das séries temporais num contexto de aprendizagem supervisionada.

Adicionalmente, optou-se por aplicar uma normalização aos dados, através da técnica *MinMax Scaler*, que transforma os valores das séries em análise num intervalo entre 0 e 1. Esta etapa é facultativa no contexto de previsão de séries temporais, quando não existem diferentes escalas, ou predominância de valores extremos, contudo no caso dos modelos de ML, demonstrou ser impactante para a obtenção de um melhor desempenho preditivo.

Por fim, para a divisão das séries em conjunto de treino e teste, optou-se pela seleção dos últimos 21 dias de cada série para amostra de teste, e definiu-se o remanescente como amostra de treino. Esta escolha de divisão teve em consideração os objetivos desta investigação, e o interesse de treinar modelos com boas capacidades preditivas numa ótica de curto prazo, sendo posteriormente testado o seu desempenho para diferentes horizontes (1 dia, 5 dias e 21 dias).

### 3.4. Implementação dos Modelos

De modo a responder à segunda questão de investigação, procurou-se identificar, com base em evidências de investigações anteriores, com foco na previsão de preços de mercado, quais os modelos que

apresentavam a melhor capacidade preditiva, tendo em consideração as diferentes Metodologias. Definiu-se que as Metodologias mais adequadas ao objetivo deste estudo são: (1) Metodologias Clássicas, destacando-se o modelo de Alisamento Exponencial (ES) e (2) as Metodologias de *Machine Learning*, com foco no modelo *Support Vector Regression* (SVR).

Ao aplicar-se estes modelos aos ETF em análise pretende-se validar se os mesmos mantêm a sua eficácia e desempenho na amostra de teste, e simultaneamente, comparar a performance das diferentes metodologias, tendo em consideração, não apenas a capacidade preditiva, como também a aplicabilidade prática e os custos computacionais associados.

### 3.4.1. Modelo Clássicos: Alisamento Exponencial (ES)

Optou-se pela seleção dos modelos clássicos de Alisamento Exponencial devido ao seu reconhecimento no âmbito das finanças e da economia, à sua fácil implementação, ao seu baixo custo computacional e aos resultados robustos destacados na literatura. Além disso, estes modelos apresentam uma boa adequação a ambientes empresariais onde a rapidez na tomada de decisão é essencial, tal como no contexto de previsão de preços de mercado.

Para uma implementação adequada destes modelos é importante considerar a análise exploratória, referida na secção 3.2.3, que permita identificar se a série é estacionária e se apresenta tendência e/ou sazonalidade. Considerando estas características é possível dividir os modelos ES em três grupos:

- *Single Exponential Smoothing*: (N, N) - a suavização exponencial simples, onde o modelo parte do princípio de que os dados são estacionários (ou seja, sem tendência nem sazonalidade), sendo adequado para séries com um comportamento relativamente constante ao longo do tempo.
- *Double Exponential Smoothing*: (A, N) e (Ad, N) - a suavização exponencial dupla (modelo de *Holt*) é adequada ao contexto de séries não estacionárias que apresentam padrões de tendência.
- *Triple Exponential Smoothing*: (N, A), (A, A), (Ad, A), (N, M), (A, M) e (Ad, M) - a suavização exponencial tripla (modelo de *Holt-Winters*), é um modelo que à componente de tendência adiciona também a componente sazonal.

Existem assim, um total de nove variações principais do modelo de Alisamento Exponencial (ver Tabela 1.) resultantes das diferentes combinações entre o tratamento (ou não) da tendência e da sazonalidade, bem como da forma (aditiva ou multiplicativa) como essas componentes são modeladas.

**Tabela 1** - Classificação dos modelos de Alisamento Exponencial

Componente de tendência (T)	Componente sazonal (S)		
	Nenhuma (N)	Modelo Aditivo (A)	Modelo Multiplicativo (M)
Nenhuma (N)	(N, N)	(N, A)	(N, M)
Modelo Aditivo (A)	(A, N)	(A, A)	(A, M)
Modelo Aditivo <i>Damped</i> (Ad)	(Ad, N)	(Ad, A)	(Ad, M)

Fonte: Ramos (2021)

A implementação computacional foi executada através do algoritmo de Ramos (2021), que possibilita um melhor ajuste aos padrões de cada uma das séries em análise, obtendo-se para os modelos onde existe convergência, uma otimização dos hiperparâmetros.

### 3.4.2. Modelo de *Machine Learning: Support Vector Regression (SVR)*

O SVR é um modelo baseado no *Support Vector Machine (SVM)*, mas aplicado a problemas de regressão. Ou seja, em vez de classificar os dados em categorias, como no caso do SVM, o SVR tem o intuito de prever um valor contínuo, com base num conjunto de variáveis explicativas.

O princípio base deste modelo é mapear os dados de treino para um espaço de dimensão superior utilizando uma função de mapeamento, também referida na literatura como, função *kernel* pré-definida. Dependendo dos diferentes contextos de aplicação destes modelos, as funções *kernel* podem ser lineares ou não lineares. Na literatura aquelas que mais se destacam são: a *Polynomial Kernel*, a *Hyberbolic Tangent Kernel* e a *Radial Basis Kernel* (F. Sheta et al., 2015).

Através do mapeamento dos dados de treino o modelo define uma função de regressão  $f(x)$ , que tem como objetivo, definir o hiperplano que inclui o maior número de pontos dentro de uma certa margem e tolerância ao erro, ou seja, definir o hiperplano ótimo de regressão, que se reflete na menor margem de erro. A função de regressão  $f(x)$  é representada por:

$$f(x) = \omega x^T + b \quad (3.1)$$

Onde,  $\omega$  é o vetor dos pesos,  $b$  é o termo independente (*intercept*), e  $x^T$  é o vetor de entrada.

O objetivo de otimização do SVR consiste em minimizar (3.2.) considerando as restrições (3.3.) que garantem que, os valores estimados se mantêm próximos dos valores *target*.

$$\frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (3.2.)$$

$$\begin{cases} y_i - \langle w, x_i \rangle - b; \leq \varepsilon + \xi_i \\ \langle w, x_i \rangle + b - y_i; \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (3.3.)$$

Onde,

- $\varepsilon$  corresponde à margem de tolerância ao erro;
- $C$  é o parâmetro de regularização, que permite equilibrar o erro do treino e a simplicidade do modelo. Este parâmetro representa a penalização aplicada aos erros de previsão que ultrapassem o limite de tolerância  $\varepsilon$ ;
- $\xi_i$  e  $\xi_i^*$  são as denominadas *slack variables*, que representam a distância entre os valores reais e os limites de  $\varepsilon$ .

Para Implementação deste modelo ao contexto em análise optou-se, com base na Literatura (Mostafavi & Hooman, 2025), pela utilização da função *Kernel, Radial Basis Function* (RBF). Na definição dos restantes parâmetros,  $C$  e  $\varepsilon$ , recorreu-se igualmente à análise da Literatura no âmbito de previsão de preços de mercado, procurando identificar as conjugações mais eficazes. Na investigação de F. Sheta *et al.* (2015) o modelo com melhor desempenho foi obtido fixando um  $C = 100$ , enquanto os autores Mostafavi & Hooman (2025), reportaram o melhor desempenho fixando um  $C = 1$ . Tendo em consideração ambos os estudos, estas parametrizações foram testadas no contexto desta investigação e complementadas com um processo de otimização do desempenho do modelo. Com recurso ao *Grid Search*, foi possível obter-se o melhor ajuste dos hiperparâmetros face aos dados em análise, assegurando uma melhor capacidade de adaptação do modelo aos padrões das séries e à minimização do erro de previsão. Deste modo, com as diferentes combinações de parâmetros, foram obtidos três modelos SVR distintos.

### 3.5. Seleção, validação e avaliação dos Modelos

Os métodos de seleção e validação foram implementados consoante a Metodologia dos modelos, sendo que, durante a fase de treino foi apenas selecionado um modelo de cada uma, e posteriormente aplicados aos dados de teste e utilizados para comparação entre as diferentes Metodologias.

No caso dos modelos Clássicos, para avaliar o seu desempenho foram considerados dois critérios estatísticos de comparação: o Critério de Informação de Akaike (AIC) e o Critério Bayesiano de Informação (BIC), propostos por Akaike (1974) e Schwarz (1978), respetivamente. Ou seja, para os modelos ES, será selecionado aquele que, para cada série, registar o menor valor de AIC e BIC. Adicionalmente, após a seleção do modelo, será realizada uma análise dos seus resíduos com o intuito de validar a seleção do modelo e garantir a correta adequação aos padrões das séries.

Para os modelos de ML a seleção e validação dos mesmos dividiu-se em duas fases. A primeira fase decorreu em simultâneo com o processo de treino, onde, através *GridSearch*, procurou-se encontrar o modelo que minimizasse o erro de previsão, considerando um conjunto de parametrizações fixas. Posteriormente, considerando os 3 modelos SVR obtidos através das diferentes combinações de parametrizações, procurou-se seleccionar aquele que minimizasse o erro, com base no *Mean Absolute Percentage Error* (MAPE) (3.5.) e no *Mean Absolute Error* (MAE) (3.4.).

$$MAE = \frac{\sum_{i=1}^n e_i}{n} \quad (3.4.)$$

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{y_{t+i} - \hat{y}_{t+i}}{y_{t+i}} \right|}{n} \times 100 \quad (3.5.)$$

Após a seleção dos modelos com melhor desempenho durante a fase de treino, em cada Metodologia, realiza-se a aplicação dos mesmos aos dados de teste, com o intuito de avaliar a sua capacidade preditiva. Esta avaliação terá por base a comparação entre os preços estimados e os preços observados, com recurso à visualização gráfica e, a métricas de avaliação como o MAPE (3.5.) e o MAE (3.4.). Esta análise permitirá avaliar se o desempenho dos modelos se mantém na amostra de teste, validando assim a sua capacidade preditiva.

### 3.6. Comparação dos Modelos

Esta secção terá como foco a comparação entre os modelos seleccionados, sendo consideradas duas perspetivas de análise: a quantitativa e qualitativa.

A análise quantitativa terá em consideração as métricas de avaliação, MAPE (3.4.) e MAE (3.5.), avaliando de forma comparativa o desempenho e capacidade preditiva dos modelos Clássicos e dos modelos ML. De forma complementar, a análise qualitativa tem como objetivo avaliar a complexidade computacional associado a cada modelo, considerando três dimensões:

- A Implementação: Onde se considera o tempo dedicado à implementação do modelo, ou seja, à adequação dos parâmetros e à compreensão teórica exigida. Neste contexto avalia-se com 1 (verde) o modelo cuja implementação foi a menos complexa e, com 3 (vermelho) a mais exigente;
- O Processamento: Neste ponto o critério principal é o tempo de processamento necessário para treino dos modelos e para aplicação à amostra *out-of-sample*. A classificação segue o raciocínio do ponto anterior, os modelos mais leves e rápidos recebem a melhor pontuação (1 - verde), e os mais exigentes, a mais alta (3 - vermelho);

- A Robustez e a capacidade de compreender padrões não lineares: A pontuação mais baixa (1 – verde) é atribuída aos modelos mais robustos e com maior capacidade de lidar com a volatilidade, e risco dos ativos, enquanto, a mais elevada é atribuída ao modelo com menor capacidade.

Considerando ambas as perspectivas desta análise comparativa, será obtida uma avaliação final, e selecionado o modelo que melhor se adequa ao âmbito desta investigação, permitindo assim responder à última questão da investigação.

### 3.7. Implementação Computacional


O desenvolvimento computacional desta investigação foi realizado através da versão *Python 3.12.4*, utilizando o ambiente *Jupyter Notebook*. Foram utilizadas diversas bibliotecas, nomeadamente: *pandas*, *numpy*, *matplotlib*, *seaborn*, *scipy.stats* e *statsmodels*. Através destes recursos foi possível desenvolver um processo bem estruturado para o desenvolvimento de uma análise de dados completa, e facilmente replicável para outras séries temporais financeiras. Para uma melhor estruturação do projeto foram criados três *notebooks*:

- (1) ADE - ETF no Setor de *E-commerce.ipynb*: referente à análise exploratória das séries e respetiva análise de risco;
- (2) ES\_Model.ipynb; (3) SVR\_Model.ipynb: Estes *notebook* são referentes à análise preditiva, tendo sido criado um *notebook* para cada tipo de modelo, de modo a facilitar a implementação computacional. Os mesmos foram aplicados a cada uma das séries temporais gerando para cada modelo três distintos ficheiros.



## 4. Resultados

### 4.1. Análise Exploratória dos ETF de *E-commerce*



**Fig. 1-**Evolução Temporal dos ETF de *E-commerce*

Ao analisar-se a evolução temporal das séries em estudo (ver Fig. 1. e Anexo A) verifica-se que todos os ETF registaram durante 2020 e 2021, o período de Covid-19 (destacado a vermelho na Fig. 1.), uma valorização dos seus preços de fecho, demonstrando o impacto positivo do Covid-19 na economia digital e no *E-commerce*. Após este crescimento acelerado, no início de 2021, verifica-se uma tendência decrescente dos preços destes ativos que se prolonga até meados de 2022, uma consequência direta da implementação gradual das fases de desconfinamento. Durante estes eventos extremos destacou-se que os ETF IBUY e ONLN foram os mais impactados, positiva e negativamente, ao contrário do EBIZ que demonstrou alguma estabilidade, o que para alguns perfis de investidores pode ser considerado um comportamento mais favorável.

No período entre 2023 e 2024, observa-se uma certa estabilidade nos valores dos três ETF, com oscilações positivas e negativas a impactarem de forma semelhante todos os ativos, como seria expectável, uma vez que, todos estes ativos apresentam uma forte correlação, tanto a nível de preços de fecho como dos seus retornos (ver Anexo B), ou seja, são todos igualmente afetados pelas evoluções do seu setor. Posteriormente a este período mais estável, verifica-se que, em meados de 2024, as três séries começam a evidenciar uma tendência de crescimento, mas no início de 2025, observa-se uma quebra, possivelmente, causada pela instabilidade política nos Estados Unidos da América (EUA), e pelas novas taxas ao comércio que impactaram o setor do comércio digital (destacado a laranja na Fig. 1.).

Através das estatísticas descritivas (ver Anexo C) foi possível evidenciar que o EBIZ se destaca como o ETF com menor instabilidade, registando um desvio-padrão de 5.9, enquanto o IBUY e o ONLN, apesar de registarem os valores máximos e médios mais elevados, apresentam também uma maior dispersão entre os seus valores. Para complementar estas observações procedeu-se à análise das distribuições das séries (ver Anexo D e Anexo E), onde se concluiu que todas as séries apresentam uma distribuição assimétrica à direita, um resultado comum em séries temporais dos mercados financeiros.

Esta conclusão é suportada pelo teste de *Skewness* (ver Tabela 2), onde se confirma que todas as séries têm uma assimetria positiva, ou seja, existe uma maior concentração dos preços de fecho abaixo da média. Observando os valores da *Kurtosis*, (ver Tabela 2) os preços de fecho do EBIZ apresentam uma curva mais achatada (platicúrtica), enquanto os preços do IBUY e do ONLN evidenciam curvas leptocúrticas. Esta diferença entre as séries permite reforçar que o EBIZ tende a apresentar um comportamento mais estável, enquanto os restantes ETF evidenciam uma maior volatilidade e uma maior ocorrência de eventos extremos.

Considerando os resultados anteriores conclui-se a priori que as séries em análise não seguem uma distribuição aproximadamente normal, porém, de modo a validar esta afirmação foram aplicados os testes de normalidade, Jarque-Bera e Kolmogorov-Smirnov (ver Tabela 2), que validam que não há evidências estatísticas de que as séries sigam uma distribuição aproximadamente normal, destacando um desafio à modelação e previsão dos preços de mercado.

**Tabela 2-** Análise Inferencial: Testes de normalidade, estacionaridade e independência

	Testes de Normalidade				Testes de Raiz unitária/ Estacionaridade		Teste de Independência
	Kurtosis	Skewness	JarqueBera	Kolmogorov-Smirnov	ADF	KPSS	BDS (Dim. 2 – Dim. 6)
<b>EBIZ</b>	<i>statistic</i> : -15.78 <i>p-value</i> : 0.00*	<i>statistic</i> : 8.73 <i>p-value</i> : 0.00*	<i>p-value</i> : 0.00*	<i>p-value</i> : 0.00*	<i>p-value</i> : 0.50 **	<i>p-value</i> : 0.02*	<i>statistic</i> : 161.54 - 267.72 <i>p-value</i> : 0.00*
<b>IBUY</b>	<i>statistic</i> : 1.30 <i>p-value</i> : 0.19**	<i>statistic</i> : 16.04 <i>p-value</i> : 0.00*	<i>p-value</i> : 0.00*	<i>p-value</i> : 0.00*	<i>p-value</i> : 0.66 **	<i>p-value</i> : 0.01*	<i>statistic</i> : 3.95 - 11.74 <i>p-value</i> : 0.00*
<b>ONLN</b>	<i>statistic</i> : 0.33 <i>p-value</i> : 0.74**	<i>statistic</i> : 15.10 <i>p-value</i> : 0.00*	<i>p-value</i> : 0.00*	<i>p-value</i> : 0.00*	<i>p-value</i> : 0.62 **	<i>p-value</i> : 0.01*	<i>statistic</i> : 94.57 - 141.69 <i>p-value</i> : 0.00*


\* Rejeita-se H0 para os níveis de significância 1%, 5% e 10%

\*\* Não se Rejeita H0 para o nível de significância 1%


Através das representações gráficas na Fig. 1. e no Anexo F (gráficos ACF e PACF) é observável que não se trata de séries estacionárias. Porém, de modo a validar esta observação recorreu-se aos testes estatísticos *Augmented Dickey-Fuller* (ADF) e *Kwiatkowski-Phillips-Schmidt-Shin* (KPSS) (ver Tabela 2). Para todas as séries, os resultados dos testes mostraram-se consistentes: no teste ADF não se rejeita a hipótese de raiz unitária e no teste KPSS rejeita-se a hipótese de estacionaridade, concluindo-se que as séries não são estacionárias, o que poderá ser outro desafio na fase de modelação. Para finalizar a análise inferencial, recorreu-se ao teste *Brock-Dechert-Scheinkman* (BDS), para detetar a existência de dependência não-linear nas séries em análise. Observando os resultados na Tabela 2 conclui-se que todas as séries apresentam dependência temporal, garantindo-se assim que as séries não apresentam *White-noise*, uma vez que apresentam correlação e dependência temporal.

Além da estacionaridade e normalidade das séries temporais, é também importante proceder à decomposição (ver Anexo G) das mesmas para analisar a existência ou não de componentes como a sazonalidade e a tendência, fatores importantes para a seleção dos modelos de previsão mais adequados.

Devido à natureza dos preços de ativos financeiros cotados, é comum que não se registem padrões de sazonalidade, tal como é visível no Anexo G e, através dos *boxplots* mensais (ver Fig. 2., Fig. 3., Fig. 4.), onde se visualiza a distribuição dos preços de mercado nos últimos 36 meses das séries. As séries em estudo não apresentam características de sazonalidade, sendo as suas variações explicadas pelos ciclos do mercado onde estão inseridas, e por fatores externos. Analisando a componente tendência, até 2021, os três ETF apresentam uma tendência positiva, seguida de uma estabilização dos preços. Porém, como visível nos *boxplots* mensais (ver Fig. 2., Fig. 3., Fig. 4.), durante os últimos meses os três ativos têm registado uma ligeira tendência de crescimento.



**Fig. 2-** Distribuição dos preços de fecho da EBIZ nos últimos 36 meses da série



**Fig. 3-** Distribuição dos preços de fecho da IBUY nos últimos 36 meses da série




Fig. 4- Distribuição dos preços de fecho da ONLN nos últimos 36 meses da série

Com a execução desta análise exploratória conclui-se que estes três ativos apresentam reações semelhantes ao longo dos eventos extremos que ocorreram nos anos em análise, sendo que, o EBIZ se destaca pela sua maior estabilidade durante os mesmos. Em termos de características das séries, verificou-se que as mesmas não são estacionárias, registrando tendências em período específicos e ausência de sazonalidade, e que não apresentam uma distribuição aproximadamente normal. Todas estas características são fundamentais para a seleção de modelos adequados e robustos capazes de modelizar dados com esta complexidade.

#### 4.2. Análise de Risco dos ETF de *E-commerce*

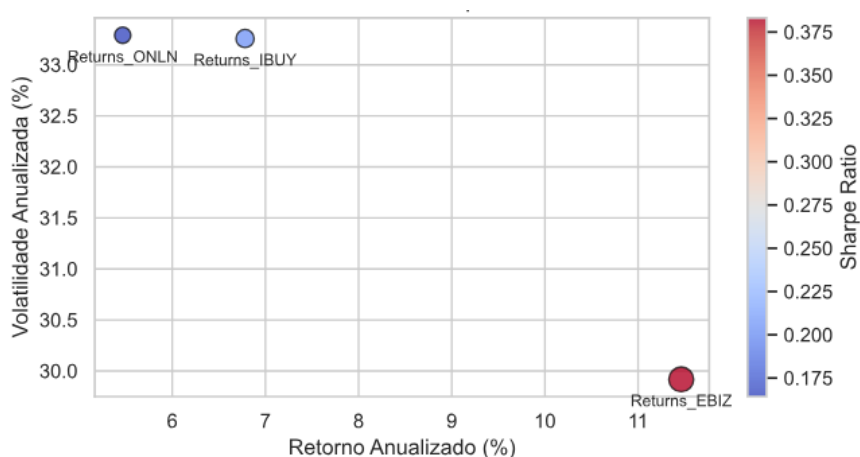
A Análise de Risco foi desenvolvida com base nos retornos logarítmicos dos preços de fecho e, para o seu desenvolvimento, foi elaborada a verificação da qualidade dos dados e a respetiva análise exploratória. Porém, dado os objetivos deste estudo, o foco desta secção foi dirigido à análise dos resultados das métricas de Risco.

Analisando a assimetria da distribuição dos retornos, através da *Skewness* (ver Anexo H), verifica-se que todos os ETF em análise apresentam uma leve assimetria negativa. Isto demonstra que, embora exista uma maior concentração de retornos positivos, no horizonte em estudo, a cauda esquerda das distribuições é ligeiramente mais pesada, evidenciado uma maior probabilidade de ocorrência de perdas significativas. Contudo, ao verificar-se os histogramas dos retornos (ver Anexo I) e as respetivas curvas de densidade, observa-se que essa assimetria é muito pouco representativa sendo que, no horizonte em análise, a ocorrência de retornos positivos e retornos negativos é muito equilibrada.

Observando os resultados do Anexo H, verifica-se que os três ETF registam níveis de volatilidade elevados, e semelhantes entre os mesmos, refletindo que este setor poderá estar associado a um nível de risco mais alto, o que pode ser considerado pouco atrativo para investidores com maior aversão ao risco. Em termos do retorno anualizado, verificam-se novamente valores próximos, contudo o EBIZ volta a destacar-se pela sua percentagem mais atrativa. Considerando a ótica de investimento, é

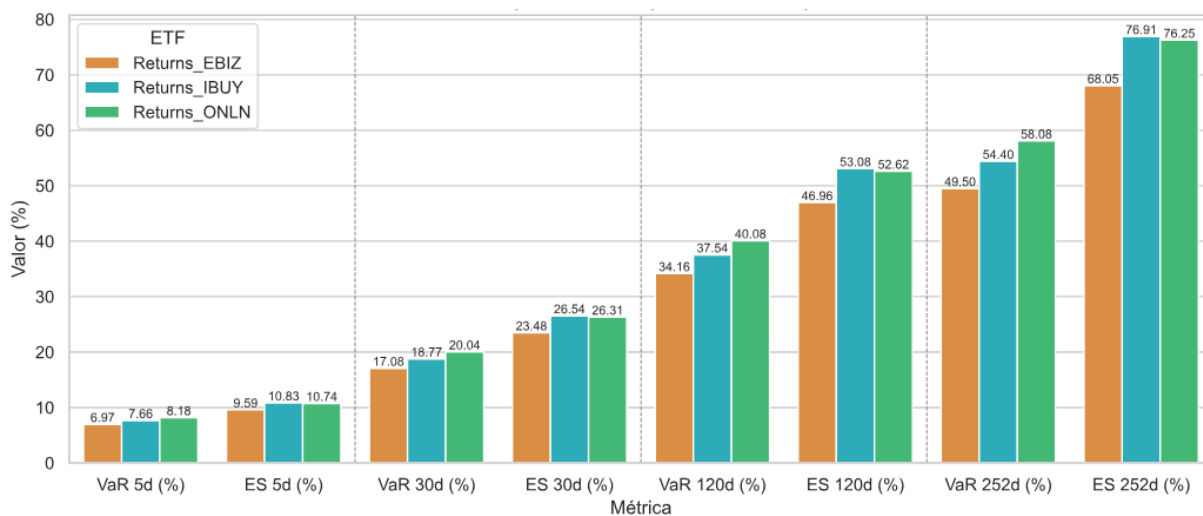
importante analisar estas duas métricas em conjunto, ou seja, analisar a relação entre o retorno e o risco, tal como é possível observar através do gráfico de dispersão na Fig. 5.

Através do gráfico verifica-se que o ETF EBIZ apresenta a menor volatilidade e o maior retorno anualizado quando comparado com o ONLN e o IBUY, que associado às elevadas volatilidades não apresentam um Retorno tão elevado como o EBIZ. Verifica-se assim que o EBIZ se encontra no quadrante mais favorável em termos de relação entre risco e retorno o que também é representado pelo seu valor de *Sharpe Ratio* (ver Fig. 5. e Anexo H) mais elevado em comparação com os restantes ativos.



**Fig. 5** - Relação entre Retorno e Volatilidade, considerando os pesos do Sharpe Ratio

De modo a complementar esta análise foram calculadas duas métricas de risco de perda (o VaR e o ES) máxima e analisada a sua evolução para diferentes horizontes temporais (ver os respetivos valores e a sua evolução na Fig. 6.).



**Fig. 6**-Comparação da evolução do Risco de perda máxima entre os três ETF

Para um horizonte de curto prazo (5 dias), as diferenças entre o VaR e o ES dos diferentes ETF são pouco evidentes, demonstrando que, num horizonte de curto prazo, os ETF apresentam probabilidades de perda muito semelhantes. Contudo, à medida que o horizonte aumenta (30, 120, 252 dias), o EBIZ exibe de forma constante menores perdas máximas esperadas, enquanto o IBUY e o ONLN revelam um aumento mais acentuado da exposição a perdas.

Compilando esta análise de risco com as conclusões da análise exploratória, conclui-se que embora os três ETF apresentem características e perfis de risco semelhantes, o EBIZ oferece uma maior estabilidade perante eventos extremos, um melhor retorno ajustado ao risco (*Sharpe Ratio*) e uma menor exposição a perdas extremas (VaR e ES), principalmente num contexto de longo prazo. Contudo, é importante referir que esta análise de risco baseou-se apenas na comparação entre os ativos em estudo, sendo que, para um investidor com aversão ao risco, estes ativos podem não ser tão atrativos, uma vez que exigem uma maior tolerância a oscilações.

### **4.3. Modelação e Previsão das Séries Temporais**

Nesta secção serão apresentados os resultados obtidos na implementação dos modelos e a sua respetiva seleção e validação, como descrito na secção 3.4. Para uma melhor apresentação dos resultados os mesmos serão organizados de acordo com as metodologias adotadas, ou seja, modelos Clássicos e modelos de *Machine Learning*.

#### **4.3.1. Modelos de Alisamento Exponencial (ES)**

Durante a implementação dos modelos ES verificou-se que, entre as nove possíveis combinações, foram obtidos três modelos ES para cada uma das séries em estudo. Todos os modelos ES aplicados aos ETF apresentaram convergência para modelos ES (N,N) e ES (A,N). Contudo, no caso do ETF EBIZ, os parâmetros do modelo convergiram também para um terceiro modelo ES (A,M), enquanto para o ONLN e o IBUY obtiveram-se modelos ES (Ad,N). Analisando graficamente a adequação dos modelos à amostra de treino verifica-se uma performance satisfatória de todos os modelos, à exceção do modelo ES (Ad,N) na previsão dos valores de fecho do ETF ONLN (ver Anexo J). Destaca-se neste exemplo que apesar de o aumento de complexidade do modelo, não se obteve uma melhor adequação aos padrões da série.

Para seleção do modelo mais adequado para cada série, recorreu-se à análise do AIC e BIC, onde se identificou que, no caso do EBIZ e do IBUY (ver Anexo K), o modelo ES (N,N) destacou-se por apresentar os valores mais baixos de AIC e BIC. Porém, no caso da série ONLN (ver Anexo K) verificou-se que tanto o ES (N,N), como o ES (A,N) apresentavam igualmente os valores mais baixos de AIC e

BIC. Neste caso, devido às características da série (ver secção 4.1.) e, comparando com os resultados obtidos nas outras séries, considerou-se o modelo ES (N,N) como o mais adequado.

Selecionados os modelos para cada série, conclui-se que as mesmas apresentam uma consistência e similaridade nos resultados obtidos, uma vez que, para todos os ETF o modelo selecionado para fins de previsão foi o ES (N,N), uma conclusão expectável devido às similaridades das séries como evidenciado na secção 4.1..

Para validar a adequação dos modelos, procedeu-se ao estudo dos resíduos gerados no processo de treino das séries. Com o objetivo de verificar a presença de *White-noise* nos resíduos, analisou-se a correlação dos mesmos, através dos gráficos PACF e ACF (ver Anexo L) e, a sua independência, através do teste BDS (ver Tabela 3). Analisando os gráficos PACF e ACF conclui-se que os resíduos dos três modelos aparentam ser aleatórios e não correlacionados, demonstrando assim uma boa adequação dos modelos aos padrões das respetivas séries. Porém, observando os resultados do teste BDS, ao rejeitar-se a hipótese nula, observa-se que pode ainda existir relações entre os dados que não estão a ser captadas por estes modelos. Ao executar os testes à normalidade e variância dos resíduos (ver Tabela 3.), verifica-se que os resíduos não seguem uma distribuição normal e apresentam heterocedasticidade condicional, complementando a conclusão anterior.

**Tabela 3** - Análise Inferencial aos Resíduos dos modelos ES(N,N): Testes de normalidade, variância e independência

Resíduos ES (N,N)	Testes à Normalidade				Análise da Variância	Teste de Independência
	Kurtosis	Skwenwss	Jarque-Bera	Kolmogorov- Smirnov	ARCH	BDS (Dim.2 - Dim.6)
<b>IBUY</b>	<i>p-value</i> 0.00* <i>statistics</i> : 2.32	<i>p-value</i> : 0.00* <i>statistics</i> : -0.31	<i>p-value</i> : 0.00*	<i>p-value</i> : 0.00*	<i>p-value</i> : 0.00*	<i>p-value</i> : 0.05 - 0.64 **
<b>ONLN</b>	<i>p-value</i> : 0.00 <i>statistics</i> : 2.34	<i>p-value</i> : 0.00* <i>statistics</i> : -0.21	<i>p-value</i> : 0.00*	<i>p-value</i> : 0.00*	<i>p-value</i> : 0.00*	<i>p-value</i> : 0.11 - 0.70 **
<b>EBIZ</b>	<i>p-value</i> : 0.00* <i>statistics</i> : 1.52	<i>p-value</i> : 0.00* <i>statistics</i> : -0.12	<i>p-value</i> : 0.00*	<i>p-value</i> : 0.00*	<i>p-value</i> : 0.00*	<i>p-value</i> : 0.25 - 0.81**

\* Rejeita-se H0 para os níveis de significância 1%, 5% e 10%

\*\* Não se Rejeita H0 para o nível de significância 1%

Estes resultados de validação sugerem que os modelos, apesar de demonstrarem uma adequação satisfatória aos padrões de comportamento destes ETF de *E-commerce*, podiam ser complementados por modelos capazes de lidar com as características de heterocedasticidade dos resíduos, tal como, o modelo GARCH, ou por outros modelos mais complexos capazes de lidar com a não linearidade dos dados.

Após a validação procedeu-se à aplicação dos modelos ES (N,N) aos dados de teste de cada série. Observando graficamente o desempenho dos modelos nas amostras de teste (ver Fig. 7., 8. e 9.) verifica-se que todos os modelos apresentam um desempenho consistente e estável ao longo de todo o horizonte.




Fig. 7- ES (N,N) EBIZ - Comparação entre os valores previstos e observados




Fig. 8 - ES (N,N) IBUY - Comparação entre os valores previstos e observados




Fig. 9- ES (N,N) ONLN - Comparação entre os valores previstos e observados

Porém, apesar das oscilações entre os valores estimados e observados, destaca-se que no horizonte de curto prazo, aproximadamente 3 dias, o valor de previsão não apresenta uma diferença significativa em relação ao valor observado. Por esta razão, procedeu-se à análise do MAE e MAPE para os diferentes horizontes temporais (ver Tabela 4.).

Tabela 4 - Análise do Desempenho dos modelos ES (N,N) na amostra de teste

	IBUY - ES (N, N)			ONLN- ES (N, N)			EBIZ - ES (N, N)		
	1 dia	5 dias	21 dias	1 dia	5 dias	21 dias	1 dia	5 dias	21 dias
<b>MAE</b>	0.11	2.20	2.63	0.38	1.93	3.30	0.11	1.13	1.96
<b>MAPE (%)</b>	0.18%	3.92%	4.63%	0.88%	4.86%	8.38%	0.39%	4.40%	7.66%

Analisando os erros de previsão verifica-se que, de um modo geral, os modelos apresentam um desempenho semelhante ao longo das três séries, embora a sua capacidade preditiva diminua ao longo da evolução do horizonte temporal. Para um objetivo de previsão de curto prazo, como a previsão do


preço do dia seguinte, os modelos apresentam todos uma boa capacidade preditiva, com valores de MAE inferiores a 0.5 e valores de MAPE inferiores a 1%. Contudo, estas métricas tendem a registar um aumento à medida que o horizonte de previsão aumenta, restringindo assim a aplicação destes modelos a previsões de preços de mercado de longo prazo.

Os resultados obtidos nesta secção realçam a capacidade preditiva dos modelos de Alisamento Exponencial para o âmbito de aplicação deste estudo, em particular do modelo ES (N,N), que apesar de ser um modelo com menor complexidade, assegura um ajuste consistente aos padrões das séries, e garante uma boa capacidade preditiva numa ótica de previsão de curto prazo. No entanto, também se observaram algumas limitações perante a análise dos seus resíduos, e no âmbito de previsão de longo prazo, evidenciando a necessidade de se recorrer a modelos mais robustos capazes de lidar com a não linearidade dos dados e respetiva heterocedasticidade.


#### 4.3.2. Modelos de SVR

Ao aplicar-se os modelos SVR aos dados de Treino verificou-se que o desempenho dos modelos não evidenciava melhorias significativas entre a utilização de 1 ou 5 *lags* (Anexo M.). Por esta razão, optou-se pela apresentação dos resultados dos modelos com 1 *lag*, uma vez que, em termos computacionais, são modelos mais simples e apresentam uma capacidade preditiva idêntica aos modelos de 5 *lags*.


Com recurso à ferramenta *Grid Search* foram aplicados a cada ETF três modelos SVR com diferentes parametrizações. Contudo, apesar das diferentes combinações de parâmetros, os modelos demonstraram desempenhos muito semelhantes, graficamente e também em termos de erro, como é possível observar nos Anexos M e N. Considerando que, em termos de erro preditivo, o ajuste dos modelos aos dados de treino é praticamente idêntico, a seleção do modelo mais adequado ao objetivo desta investigação baseou-se essencialmente na seleção do modelo que garantisse a melhor relação entre minimização do erro e do custo computacional, ou seja, o modelo com: o menor valor de MAE e MAPE, o menor número de *lags*, o parâmetro  $C$  mais baixo e o parâmetro  $\epsilon$  mais alto. Deste modo, selecionou-se o modelo SVR 3 com os parâmetros  $C=10$  e  $\epsilon=0.01$ , sendo este o modelo com menor complexidade, em termos de penalização do erro, quando comparado com um  $C=100$  ou  $C=1000$ , e com uma maior margem de tolerância ao erro. Selecionado o modelo, procedeu-se à aplicação do mesmo aos 21 dias fora do horizonte de treino (ver Fig. 10., 11. e 12.).



**Fig. 10** - SVR 3 EBIZ ( $C=10$ ;  $\epsilon=0.01$ ) - Comparação dos valores previstos e observados



**Fig. 11** - SVR 3 IBUY ( $C=10$ ;  $\epsilon=0.01$ ) - Comparação dos valores previstos e observados



**Fig. 12** - SVR 3 ONLN ( $C=10$ ;  $\epsilon=0.01$ ) - Comparação dos valores previstos e observados

Ao contrário do verificado na amostra de treino (Anexo N.) as previsões da amostra de teste não apresentam um desempenho tão preciso, mas apresentam uma boa performance ao longo de todo o horizonte. Esta afirmação é complementada pela análise das medidas de erro MAE e MAPE (ver Tabela 5), onde o modelo selecionado para cada série mostrou-se adequado, evidenciado um bom desempenho na amostra de treino e de teste, ainda que com um ligeiro aumento do erro.

**Tabela 5** - Análise do Desempenho dos modelos SVR nas amostras de teste

	SVR 3 (C = 10; $\epsilon$ = 0.01) - EBIZ			SVR 3 (C = 10; $\epsilon$ = 0.01) - IBUY			SVR 3 (C = 10; $\epsilon$ = 0.01) - ONLN		
	1 dia	5 dias	21 dias	1 dia	5 dias	21 dias	1 dia	5 dias	21 dias
MAE	0.08	0.86	0.60	0.05	1.80	1.40	0.35	1.42	1.03
MAPE (%)	0.29%	3.30%	2.30%	0.09%	3.17%	2.43%	0.80%	3.52%	2.57%

O modelo aplicado ao EBIZ apresenta ser o mais ajustado aos dados das séries, contudo é importante considerar que, entre os três ETF estudados, o EBIZ é o que registra a menor volatilidade de preços, razão pela qual o erro de previsão é ligeiramente menor no seu caso. Segue-se o modelo SVR aplicado ao ONLN e ao IBUY, com desempenhos ligeiramente inferiores, mas adequados ao perfil de risco dos ativos em comparação com o EBIZ. De um modo geral, os modelos SVR selecionados demonstraram uma boa adequação aos padrões dos ETF de *E-commerce* registrando para um horizonte de 1 dia, um erro médio absoluto, inferior a 1 e, um erro médio relativo inferior a 1%, métricas competitivas na previsão de preços de mercado do dia seguinte. Entre o 5º dia e o 21º dia de previsão, observa-se uma tendência contraditória do erro, uma vez que, seria esperado que o mesmo aumentasse consoante a extensão do horizonte. Este fator ocorre excepcionalmente, devido ao impacto das tarifas ao comércio que levaram a uma queda inesperada dos preços, afetando a previsão do horizonte de 5 dias em benefício dos 21 dias. No entanto, apesar do agravamento do erro nestes horizontes, os valores do MAE permanecem abaixo de 1 para o ETF EBIZ e, abaixo de 2 para os ETF ONLN e IBUY, e simultaneamente, os valores do MAPE registam valores inferiores a 3.5%, refletindo uma capacidade preditiva satisfatória.

Os modelos SVR mostraram ser adequados ao objetivo desta investigação, prevendo de forma eficaz os preços de mercado de 3 ETF do setor de *E-commerce*, especialmente na ótica de previsão do preço do dia seguinte. A escolha de modelos com 1 *lag* e de parametrizações com menor complexidade demonstraram ser adequadas ao contexto em análise, não comprometendo a capacidade preditiva dos modelos e assegurando um menor custo computacional.

#### **4.4. Comparação e Discussão do desempenho das diferentes Metodologias**

A análise comparativa do desempenho das diferentes metodologias é um fator relevante para a análise de séries temporais financeiras, não só para validar que metodologias se destacam em termos de performance, mas também para refletir sobre a relação entre custo e benefício da aplicação das mesmas a determinados contextos, e assim contribuir para uma escolha metodológica mais fundamentada. Por esta razão, nesta secção procede-se a esta análise comparativa no contexto de previsão do preço dos ETF no setor do comércio eletrónico.

Esta análise tem em consideração uma dupla perspectiva: a qualidade preditiva, avaliada de forma quantitativa (ver Tabela 6), com base nos resultados da secção 4.3, e o custo computacional, avaliado de forma qualitativa (ver Tabela 7). Além destas duas perspectivas, no desenvolver deste estudo detetou-se outro fator com impacto na qualidade preditiva, a categoria de risco dos ativos. Para analisar-se este fator procedeu-se à categorização dos ETF em categorias de risco considerando a relação entre retorno e volatilidade, apresentada na secção 4.2 (ver Fig. 5.), e caracterizou-se os quadrantes da Matriz segundo a Fig. 13..

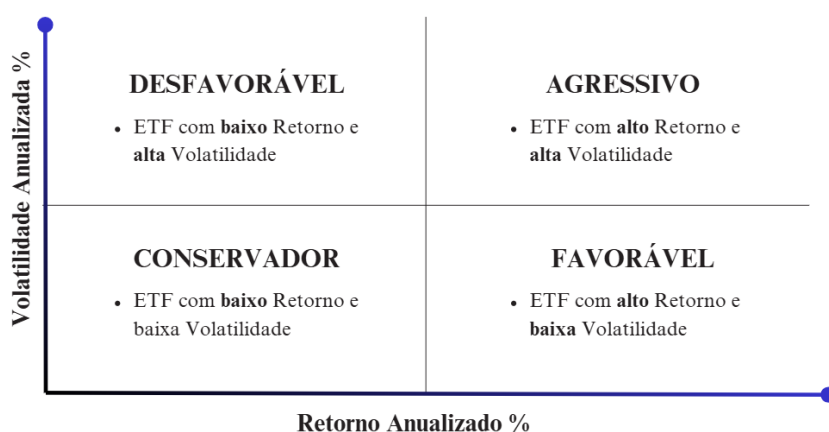


Fig. 13 - Categorias de Risco segundo a Volatilidade e o Retorno Anualizado

Tendo em conta estas quatro categorias de risco, classifica-se o ETF EBIZ como favorável e os ETF ONLN e IBUY como desfavoráveis, salientando-se que esta categorização tem apenas por base os valores destes três ativos e a comparação entre os mesmos. Incluindo as categorias de risco na Análise quantitativa dos modelos (ver Tabela 6.), valida-se a relação entre o erro e o risco dos ativos.

A análise quantitativa considera o erro no horizonte total da amostra *out-of-sample*, e de um modo geral, comparando a Metodologia Clássica com a de *Machine Learning*, verifica-se que o modelo SVR apresentou um melhor ajuste aos padrões das séries temporais, registando uma redução significativa do erro em termos absolutos (MAE) e percentuais (MAPE). Relacionando o desempenho das Metodologias com a respetiva categoria de risco conclui-se que, o Método Clássico, mostra ser o mais afetado em termos de risco médio absoluto, registando um erro de 1.96 para o ETF classificado como favorável, e de 2.63 e 3.3 para os ETF da categoria desfavorável. Ou seja, com a degradação da classe de risco, verifica-se também uma menor capacidade preditiva do modelo Clássico. Este resultado reforça a limitação destas abordagens lineares no contexto de séries temporais com maior volatilidade, ou seja, maior risco, como o ETF IBUY ( $std = 27$ ) e o ONLN ( $std = 15.84$ ). Já o SVR, inserido nas Metodologias de ML, mostra uma boa capacidade preditiva para ambas as categorias, sendo o aumento de erro pouco

significativo consoante a degradação da classe de risco, evidenciado a adaptabilidade do modelo aos diferentes perfis de risco.









**Tabela 6** - Análise quantitativa da capacidade preditiva das diferentes metodologias

		<b>EBIZ</b>		<b>IBUY</b>		<b>ONLN</b>	
		<b>ES</b>	<b>SVR</b>	<b>ES</b>	<b>SVR</b>	<b>ES</b>	<b>SVR</b>
<b>Análise</b>	<b>MAE</b>	1.96	0.60	2.63	1.40	3.30	1.03
<b>Quantitativa</b>	<b>MAPE %</b>	7.66%	2.30%	4.63%	2.43%	8.38%	2.57%
<b>Categoria de Risco</b>		Favorável		Desfavorável		Desfavorável	

Para avaliar a Complexidade Computacional (ver Tabela 7.), procedeu-se a uma análise qualitativa decomposta em três categorias com igual ponderação na avaliação final, a implementação, o processamento e a robustez (ver secção 3.6.).

O modelo de Alisamento Exponencial (ES), classificado em termos quantitativos como o modelo com o maior erro, destaca-se na análise qualitativa pela sua simples implementação, em comparação com as metodologias de ML, e pelo seu nível médio de processamento. No entanto, em termos de tempo de processamento, foi ultrapassado pelo SVR. A Metodologia de ML selecionada, demonstrou ser mais eficiente em termos de processamento, e apresentou a melhor capacidade para compreender os padrões das séries, independentemente da não linearidade das séries e dos níveis de risco dos ativos. No âmbito desta investigação, considerando a média entre as três categorias de avaliação da complexidade computacional, obteve-se uma classificação de Nível 2 (amarelo) para o modelo ES e de Nível 1 (verde) para o modelo SVR.

**Tabela 7** - Análise qualitativa das diferentes metodologias

		<b>ES</b>	<b>SVR</b>
<b>Análise</b> <b>Qualitativa</b>	<b>Implementação</b>		
	<b>Processamento</b>		
	<b>Robustez/ Não-linearidade</b>		
	<b>Complexidade Computacional</b>		

Compilando a análise qualitativa e quantitativa deste estudo, conclui-se que o modelo SVR oferece a melhor relação entre capacidade preditiva e custo computacional, principalmente em ativos com comportamento não-linear e volatilidade, como o ETF IBUY e ONLN.



## 5. Conclusões

Compreendida a crescente importância do mercado global dos ETF e dos setores emergentes que o rodeiam, esta investigação teve como principal objetivo caracterizar as séries temporais dos ETF EBIZ, IBUY e ONLN, inseridos no setor do comércio eletrónico, e compreender que metodologias preditivas mais se ajustavam aos padrões das séries e ao seu âmbito de aplicação, através da compilação de ferramentas de análise exploratória e preditiva, inseridas na ótica do *Business Analytics*.

Esta última secção da investigação dividida em duas partes: a primeira, focada em expor as contribuições e implicações principais deste estudo, e a segunda dedica às limitações registadas ao longo do percurso e às recomendações para investigações futuras.

### 5.1. Contribuições e implicações do estudo

Para uma melhor exposição e reflexão acerca das contribuições e implicações, esta secção encontra-se subdividida consoante as duas questões de investigação que orientaram este estudo.

#### A) De que forma se caracterizam, em termos estatísticos, as séries temporais dos ETF do setor de *E-commerce*?

Em termos estatísticos, as três séries analisadas apresentam características concordantes entre si, e semelhantes a outros ativos financeiros, tais como a ausência de estacionaridade e sazonalidade, a não normalidade, a assimetria positiva e a presença de dependência temporal. Simultaneamente, através da análise exploratória verificou-se que estes três ETF, apresentam reações idênticas perante os diferentes eventos económicos. Contudo, apesar das semelhantes constituições e da forte correlação entre os ETF, o EBIZ destacou-se constantemente ao longo desta análise devido à sua maior estabilidade, essencialmente durante os períodos de maior incerteza. As conclusões obtidas com a análise de risco, complementam as obtidas na análise exploratória, concluindo-se que, o ETF EBIZ apresenta o melhor retorno ajustado ao risco (*Sharpe Ratio*) quando comparado com o ONLN e o IBUY, e, adicionalmente, regista uma menor exposição a perdas extremas (VaR e ES), quando observado num contexto de longo prazo.

O estudo aprofundado dos padrões e características das séries temporais foi fundamental para a adequação e seleção dos modelos preditivos, salientando a necessidade de recorrer a modelos robustos, capazes de lidar com a estrutura destas séries temporais, como a sua não linearidade e volatilidade. Além disso, perante estas análises foi também possível definir que estes ETF, em específico, podem ser categorizados como produtos financeiros com um perfil de risco mais elevado. Porém, durante a exploração dos dados, é evidente a presença de uma tendência de crescimento dos seus preços de fecho,

o que para alguns investidores pode ser interpretado como uma oportunidade, reforçando, igualmente as conclusões de outros autores sobre as tendências de crescimento deste setor.

**B) Quais as metodologias de modelação mais adequadas, em termos de desempenho preditivo e eficiência computacional, para a previsão do comportamento de ETF do setor de *E-commerce*?**

No âmbito do desempenho preditivo, medido nesta investigação através dos indicadores de erro MAE e MAPE, observou-se, considerando o total do horizonte temporal, que a abordagem clássica selecionada, o modelo ES (N,N), registou um bom ajuste aos dados de treino, mas na amostra de teste evidenciou um desempenho inferior, ainda que satisfatório. No contexto da capacidade preditiva de forma desagregada, considerando a previsão para o preço do dia seguinte, esta metodologia registou um baixo erro preditivo, demonstrando-se adequada para aplicação neste contexto. Contudo, consoante o aumento do horizonte verifica-se uma degradação significativa da sua capacidade preditiva, em comparação com a metodologia de *Machine Learning*.

Os modelos SVR demonstraram de forma global um melhor desempenho preditivo, tanto no contexto de preços do dia seguinte, como para os horizontes mais alargados. Conclui-se então, que para a aplicação de modelos preditivos a séries com características semelhantes às em estudo, os modelos SVR são mais adequados quando comparados com os modelos ES. Esta conclusão é suportada pela análise das métricas de erro na amostra de teste, e pela análise qualitativa, que avalia a complexidade computacional de cada metodologia, onde, mais uma vez, o modelo SVR obteve a melhor avaliação global, realçando-se como a melhor relação entre desempenho preditivo e eficiência computacional.

Considerando os resultados obtidos e as conclusões adjacentes, demonstra-se que os objetivos propostos foram integralmente abordados e cumpridos, contribuiu positivamente em termos científicos, metodológicos e práticos.

Em termos de contributos no contexto científico, a análise exploratória permitiu uma caracterização estatística aprofundada destes ativos, contribuindo assim para o seu enquadramento em termos de perfil de risco e, possibilitando a sua comparação e posicionamento em relação a outros produtos financeiros. Adicionalmente, o destaque do EBIZ como o ativo com maior estabilidade entre os estudados, contribui também para o apoio de literatura acerca da heterogeneidade do desempenho de produtos financeiros que estão inseridos nos mesmos setores. Em relação à análise preditiva, no âmbito de científico, contribuiu para a validação da superioridade dos modelos *Machine Learning* em comparação com a metodologia clássica ES, especialmente em contexto de longo prazo, contribuindo para a literatura acerca da aplicação de modelos SVR a séries financeiras não-lineares e voláteis.

No âmbito metodológico e prático, respondendo à primeira questão de investigação, foi demonstrado como aplicar métricas estatísticas e de risco, essenciais para a avaliação de ativos financeiros,

contribuindo diretamente para a transformação destes conceitos teóricos em ferramentas de *Business Analytics*. Estas métricas podem ser aplicadas por investidores como instrumentos de apoio à tomada de decisão, avaliando o desempenho, o risco e a estabilidade dos seus ativos financeiros de forma contínua e fundamentada.

Na aplicação das metodologias de previsão, esta investigação confrontou a aplicabilidade dos modelos Clássicos e de *Machine Learning* e demonstrou que, no âmbito de previsão do dia seguinte ambas as metodologias mostram um desempenho competitivo, podendo neste sentido serem aplicadas pelos investidores para previsão dos resultados do dia seguinte, ou para apoiar a tomada de decisão de venda ou de compra dos respetivos ativos financeiros. De forma complementar, foi estabelecido um critério metodológico para a seleção dos modelos preditivos, que conjuga a capacidade preditiva e a eficiência computacional, realçando a importância de avaliar o desempenho dos modelos considerando, simultaneamente, a sua rentabilidade e a viabilidade operacional, temas importantes no âmbito de implementação de modelos preditivos no contexto do negócio.

Não obstante os contributos alcançados e as conclusões consistentes obtidas, reconhece-se que esta investigação apresenta também limitações que devem ser consideradas em futuras investigações, razão pela qual se identificam as mesmas na secção 5.2., com o intuito de que, no futuro, outros investigadores possam enriquecer os seus estudos e expandir as conclusões obtidas nesta investigação.

## **5.2. Limitações e recomendações para investigações futuras**

Finalizando esta investigação, reconhece-se que, apesar dos contributos académico e científicos, que a mesma proporcionou, existem algumas limitações que importa salientar e mitigar em futuras investigações no âmbito de previsão de séries temporais do setor financeiro. Com base nestas limitações e nas tendências da literatura atual, nesta secção apresentam-se também sugestões de investigação que surgiram ao longo do desenvolvimento do estudo.

As principais limitações assinaladas focam-se no horizonte temporal das previsões, na dimensão dos dados e na análise comparativa de risco. O estudo atual foca-se na previsão de curto prazo, testando-se a capacidade preditiva dos modelos para um horizonte máximo de 21 dias, no entanto este fator pode ser assinalado também como uma limitação, pois reduz a aplicabilidade prática dos modelos para investidores que estejam interessados em estratégias de longo prazo, como assinalado na literatura recente por Najem, Bahnasse, *et al.* (2024) e Beniwal *et al.* (2024).

Em relação à dimensão dos dados, as séries temporais analisadas abrangem uma amostra de 1590 observações e, apesar de ter sido uma amostra apropriada e suficiente para os objetivos da investigação, seria relevante, em futuros estudos, aumentar a mesma, de modo a avaliar a performance dos modelos no contexto de *Big Data*, acreditando-se que esta alteração teria mais impacto na avaliação

qualitativa (secção 4.4.) dos modelos do que na avaliação quantitativa do erro preditivo. Por fim, na discussão dos resultados da análise de risco, secção 4.2., o estudo centrou-se apenas nos 3 ETF do setor do comércio eletrónico, o que pode limitar a interpretação das métricas do risco por alguns leitores, ou seja, ao adicionar-se outros ativos mais estáveis e reconhecidos, produtos com diferentes perfis de risco, como o S&P500 ou o Índice NASDAQ, iria contribuir para uma comparação mais clara e abrangente do risco. Em suma, para mitigar estas limitações, recomenda-se a consideração de um aumento do horizonte de previsão e de treino, e adicionalmente, a incorporação de um conjunto de ativos mais diversificados, de modo a enriquecer a análise preditiva e comparativa das diferentes metodologias e aprofundar como as mesmas podem ser afetadas pelos diferentes perfis de risco.

Ao longo deste estudo, novos temas destacaram-se na literatura, muitos dos quais acredita-se que, em seguimento deste estudo, possam ser muito promissores e impactantes em termos científicos. Neste sentido recomenda-se também que, em continuidade desta investigação, se considere a inclusão de dados complementares a estas séries e a incorporação de algoritmos de *Deep Learning*, na análise de metodologias.

A recomendação dos dados complementares às séries surge associada à crescente disponibilização de dados não estruturados relacionados com os mercados financeiros e outros setores, que podem ser extraídos através de notícias, publicações, comentários de redes sociais e *dashboards* de monitorização. A incorporação deste tipo de dados não estruturado, requer a utilização de técnicas avançadas, como o *text mining* e a análise de imagens através de algoritmos de *Deep Learning*, como as *Convolutional Neural Networks* (CNN). A implementação destes dados e técnicas poderá enriquecer futuras investigações em termos metodológicos e, conseqüentemente, em termos de resultados, avaliando se os mesmos teriam um impacto positivo na redução do erro de previsão mantendo, ou não, uma boa relação em termos computacionais. Além destas aplicações mais robustas das metodologias de *Deep Learning*, seria também relevante incorporar modelos de redes neuronais a esta investigação, comparando se os mesmos ultrapassam a qualidade preditiva dos modelos de *Machine Learning*, tanto a nível de erro de previsão como de eficiência preditiva.

No contexto do *Business Analytics*, outra sugestão é a criação de um *dashboard* dinâmico, que possa ser utilizado como ferramenta de tomada de decisão para os investidores. Tendo em conta a performance dos modelos desta investigação, no contexto de curto prazo, acredita-se que a incorporação dos mesmos, em conjunto com as técnicas de análise exploratória e métricas de risco, num *dashboard* dinâmico, poderá acrescentar valor a este estudo e demonstrar a aplicabilidade destas técnicas no contexto de apoio à decisão.

Adicionalmente, considerando o foco desta investigação no setor de *E-commerce*, acredita-se que será relevante explorar se ETF inseridos em outros setores, apresentam níveis semelhantes de risco, e

se, as diferentes metodologias de previsão de preços, demonstram uma adequação idêntica aos padrões das séries. Neste contexto, outros ativos com um destaque crescente, são os ETF associados a critérios de ESG, constituindo assim uma boa oportunidade de investigação com um contributo significativo a nível científico.

Finaliza-se assim esta investigação, acreditando que a mesma contribuiu positivamente para o enriquecimento do conhecimento das limitações e vantagens das diferentes metodologias de previsão de séries temporais, e para adequação das mesmas ao contexto de ativos em setores específicos e associadas à digitalização, como o *E-commerce*. Espera-se que este estudo possa ser um ponto de partida para muitas outras investigações e que incentive a comunidade académica e científica a refletir, que nem sempre as melhores previsões estão associadas aos melhores modelos e que, a ponderação de componentes qualitativas, é também um ponto importante para seleção dos modelos a implementar.



## Referências bibliográficas (APA style)

- AlMadany, N. N., Hujran, O., Naymat, G. A., & Maghyreh, A. (2024). Forecasting cryptocurrency returns using classical statistical and deep learning techniques. *International Journal of Information Management Data Insights*, 4(2), 100251. <https://doi.org/10.1016/j.ijimei.2024.100251>
- Amplify ETFs. (s.d.). IBUY - Amplify online retail ETF. Amplify ETFs. Amplify ETFs - IBUY
- Atilgan, Y., Demirtas, K. O., Gunaydin, A. D., & Oztekin, M. (2024). Performance implications of hedging with industry ETFs. *Global Finance Journal*, 61, 100990. <https://doi.org/10.1016/j.gfj.2024.100990>
- Bansal, M., Goyal, A., & Choudhary, A. (2022). Stock Market Prediction with High Accuracy using Machine Learning Techniques. *Procedia Computer Science*, 215, 247–265. <https://doi.org/10.1016/j.procs.2022.12.028>
- Bao, W., Cao, Y., Yang, Y., Che, H., Huang, J., & Wen, S. (2025). Data-driven stock forecasting models based on neural networks: A review. *Information Fusion*, 113, 102616. <https://doi.org/10.1016/j.inffus.2024.102616>
- Beniwal, M., Singh, A., & Kumar, N. (2024). Forecasting multistep daily stock prices for long-term investment decisions: A study of deep learning models on global indices. *Engineering Applications of Artificial Intelligence*, 129, 107617. <https://doi.org/10.1016/j.engappai.2023.107617>
- Bhandari, H. N., Pokhrel, N. R., Rimal, R., Dahal, K. R., & Rimal, B. (2024). Implementation of deep learning models in predicting ESG index volatility. *Financial Innovation*, 10(1), 75. <https://doi.org/10.1186/s40854-023-00604-0>
- Brownlee, J. (2018). *Deep Learning for Time Series Forecasting: Predict the future with MLPs, CNNs and LSTMs in Python. Machine Learning Mastery.*
- Cavalcante, R. C., Brasileiro, R. C., Souza, V. L. F., Nobrega, J. P., & Oliveira, A. L. I. (2016). Computational Intelligence and Financial Markets: A Survey and Future Directions. *Expert Systems with Applications*, 55, 194–211. <https://doi.org/10.1016/j.eswa.2016.02.006>
- Dudek, G., Fiszeder, P., Kobus, P., & Orzeszko, W. (2024). Forecasting cryptocurrencies volatility using statistical and machine learning methods: A comparative study. *Applied Soft Computing*, 151, 111132. <https://doi.org/10.1016/j.asoc.2023.111132>
- A., Elsir, S., & Faris, H. (2015). A Comparison between Regression, Artificial Neural Networks and Support Vector Machines for Predicting Stock Market Index. *International Journal of*

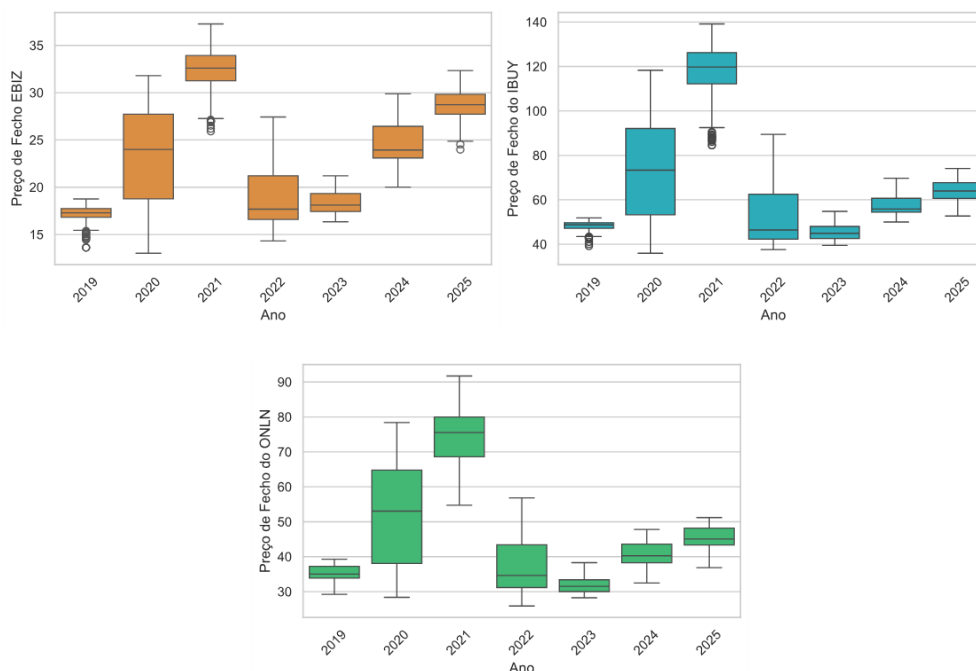
- Fonseca, C. S. G. (2012). *Gestão activa versus gestão passiva: Análise comparativa da performance dos exchange traded funds.*(Dissertação de Mestrado, Instituto Universitário de Lisboa - ISCTE Business School, Lisboa)
- Garg, Rameshwar & Barpanda, Shriya & Salanke N S, Girish & Shivamadegowda, Ramya. (2022). *Machine Learning Algorithms for Time Series Analysis and Forecasting.* <http://dx.doi.org/10.48550/arXiv.2211.14387>
- Global X ETFs. (s.d.). *E-commerce ETF (EBIZ).* Global X ETFs. E-commerce ETF (EBIZ)
- Higueras-Castillo, E., Liébana-Cabanillas, F. J., & Villarejo-Ramos, Á. F. (2023). Intention to use e-commerce vs physical shopping. Difference between consumers in the post-COVID era. *Journal of Business Research*, 157, 113622. <https://doi.org/10.1016/j.jbusres.2022.113622>
- Hoque, M. E., Billah, M., Alam, M. R., & Lucey, B. (2024). Does news related to digital economy and central bank digital currency affect digital economy ETFs? Evidence from TVP-VAR connectedness and wavelet local multiple correlation analyses. *Global Finance Journal*, 61, 100992. <https://doi.org/10.1016/j.gfj.2024.100992>
- Joshi, G., Dash, R. Exchange-traded funds and the future of passive investments: a bibliometric review and future research agenda. *Futur Bus J* 10, 17 (2024). <https://doi.org/10.1186/s43093-024-00306-8F>.
- Kalıpçı, M. B., Şimşek, E. K., & Eren, R. (2024). Decoding the trends and the emerging research directions of E-commerce and tourism in the light of Resource Dependence Theory: A bibliometric analysis. *Heliyon*, 10(6), e28076. <https://doi.org/10.1016/j.heliyon.2024.e28076>
- Kolanovic, M. & Kaplan, B. (2024). *JPM 2024 Global ETF Handbook.*J.P.Morgan
- Kumar, D., Sarangi, P. K., & Verma, R. (2022). A systematic review of stock market prediction using machine learning and statistical techniques. *Materials Today: Proceedings*, 49, 3187–3191. <https://doi.org/10.1016/j.matpr.2020.11.399>
- Lettau, M., & Madhavan, A. (2018). Exchange-Traded Funds 101 for Economists. *Journal of Economic Perspectives*, 32(1), 135–154. <https://doi.org/10.1257/jep.32.1.135>
- Mostafavi, S. M., & Hooman, A. R. (2025). Key technical indicators for stock market prediction. *Machine Learning with Applications*, 20, 100631. <https://doi.org/10.1016/j.mlwa.2025.100631>
- Najem, R., Amr, M. F., Bahnasse, A., & Talea, M. (2024). Advancements in Artificial Intelligence and Machine Learning for Stock Market Prediction: A Comprehensive Analysis of Techniques and Case Studies. *Procedia Computer Science*, 231, 198–204. <https://doi.org/10.1016/j.procs.2023.12.193>

- Najem, R., Bahnasse, A., & Talea, M. (2024). Toward an Enhanced Stock Market Forecasting with Machine Learning and Deep Learning Models. *Procedia Computer Science*, 241, 97–103. <https://doi.org/10.1016/j.procs.2024.08.015>
- Paul A. Pavlou (2003) Consumer Acceptance of Electronic Commerce: Integrating Trust and Risk with the Technology Acceptance Model, *International Journal of Electronic Commerce*, 7:3, 101-134. <http://dx.doi.org/10.1080/10864415.2003.11044275>
- Pratas, T. E., Ramos, F. R., & Rubio, L. (2023). Forecasting bitcoin volatility: Exploring the potential of deep learning. *Eurasian Economic Review*, 13(2), 285–305. <https://doi.org/10.1007/s40822-023-00232-0>
- Pratas, T. E. T. (2022). Forecasting Bitcoin's Volatility: Exploring the Potential of Deep-Learning. (Dissertação de Mestrado, Instituto Universitário de Lisboa - ISCTE Business School, Lisboa)
- ProShares. (s.d.). Online retail ETF (ONLN). ProShares. ONLN | Online Retail ETF | ProShares
- Ramos, F.R.: Data Science na Modelação e Previsão de Séries Económico-financeiras: das Metodologias Clássicas ao Deep Learning. (PhD Thesis, Instituto Universitário de Lisboa - ISCTE Business School, Lisboa (2021). <https://doi.org/10.13140/RG.2.2.14510.02887>
- Ramos, F. R., Martínez, L. M., & Martínez, L. F. (2024). Trends and Forecasts for Sales and Employment: An Overview of the e-Commerce Sector. Em F. J. Martínez-López, L. F. Martínez, & P. Brüggemann (Eds.), *Advances in Digital Marketing and eCommerce* (pp. 31–40). Springer Nature Switzerland. [https://doi.org/10.1007/978-3-031-62135-2\\_5](https://doi.org/10.1007/978-3-031-62135-2_5)
- Schröer, C., Kruse, F., & Gómez, J. M. (2021). A Systematic Literature Review on Applying CRISP-DM Process Model. *Procedia Computer Science*, 181, 526–534. <https://doi.org/10.1016/j.procs.2021.01.199>
- Sezer, O. B., Gudelek, M. U., & Ozbayoglu, A. M. (2020). Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied Soft Computing*, 90, 106181. <https://doi.org/10.1016/j.asoc.2020.106181>
- Tealab, A. (2018). Time series forecasting using artificial neural networks methodologies: A systematic review. *Future Computing and Informatics Journal*, 3(2), 334–340. <https://doi.org/10.1016/j.fcij.2018.10.003>
- Vijh, M., Chandola, D., Tikkiwal, V. A., & Kumar, A. (2020). Stock Closing Price Prediction using Machine Learning Techniques. *Procedia Computer Science*, 167, 599–606. <https://doi.org/10.1016/j.procs.2020.03.326>
- Wilson, J. H., Dingus, R., & Hoyle, J. (2020). Women count: Perceptions of forecasting in sales. *Business Horizons*, 63(5), 637–646. <https://doi.org/10.1016/j.bushor.2020.06.001>


- Zhang, G., Eddy Patuwo, B., & Y. Hu, M. (1998). Forecasting with artificial neural networks: International Journal of Forecasting, 14(1), 35–62. [https://doi.org/10.1016/S0169-2070\(97\)00044-7](https://doi.org/10.1016/S0169-2070(97)00044-7)
- Zhao, C., Wu, M., Liu, J., Duan, Z., Li, J., Shen, L., Shangguan, X., Liu, D., & Wang, Y. (2023). Progress and prospects of data-driven stock price forecasting research. International Journal of Cognitive Computing in Engineering, 4, 100–108. <https://doi.org/10.1016/j.ijcce.2023.03.001>

## Anexos

### Anexo A. Distribuição dos preços de fecho ao longo dos anos em análise




### Anexo B. Análise de Correlação dos Preços de Fecho e dos Retornos dos ETF



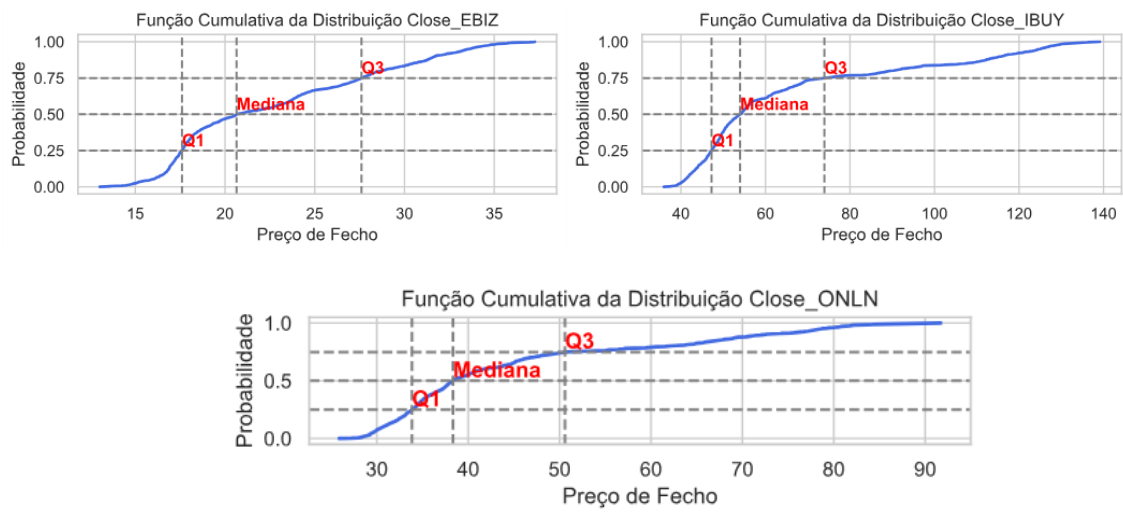
### Anexo C. Estatísticas Descritivas dos Preços de Fecho dos ETF

	N	Média	std	Min	Q1	Mediana	Q3	Max	Skewness	Kurtosis
<b>EBIZ</b>	1590	22.73	5.96	13.02	17.60	20.64	27.60	37.27	0.57	2.07
<b>IBUY</b>	1590	65.83	27.00	35.95	47.24	53.99	73.94	139.13	1.23	3.16
<b>ONLN</b>	1590	45.19	15.84	25.89	33.84	38.33	50.59	91.70	1.13	3.03

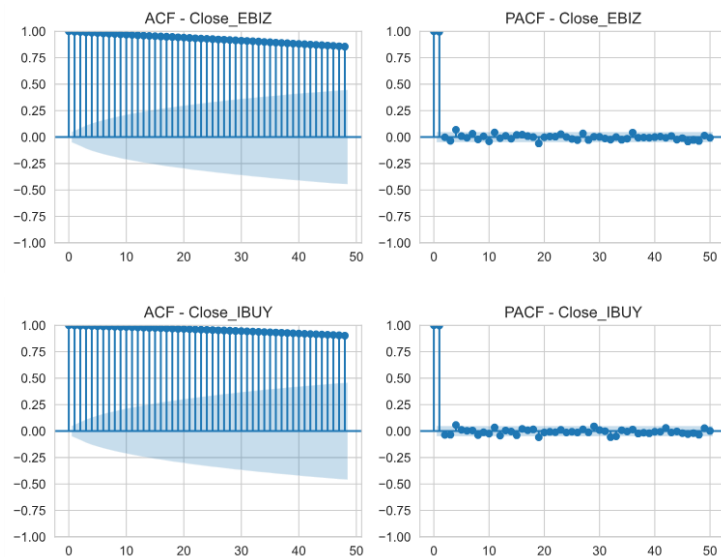
## Anexo D. Histogramas e Curvas de Densidade




## Anexo E. Funções Cumulativas das Distribuições

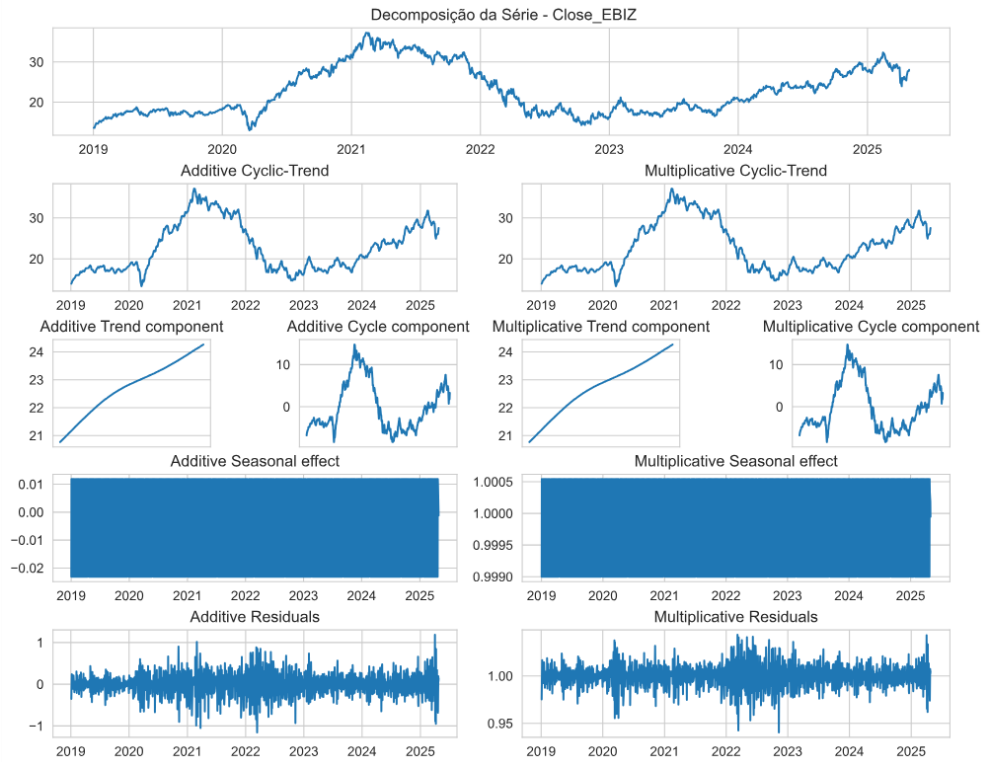


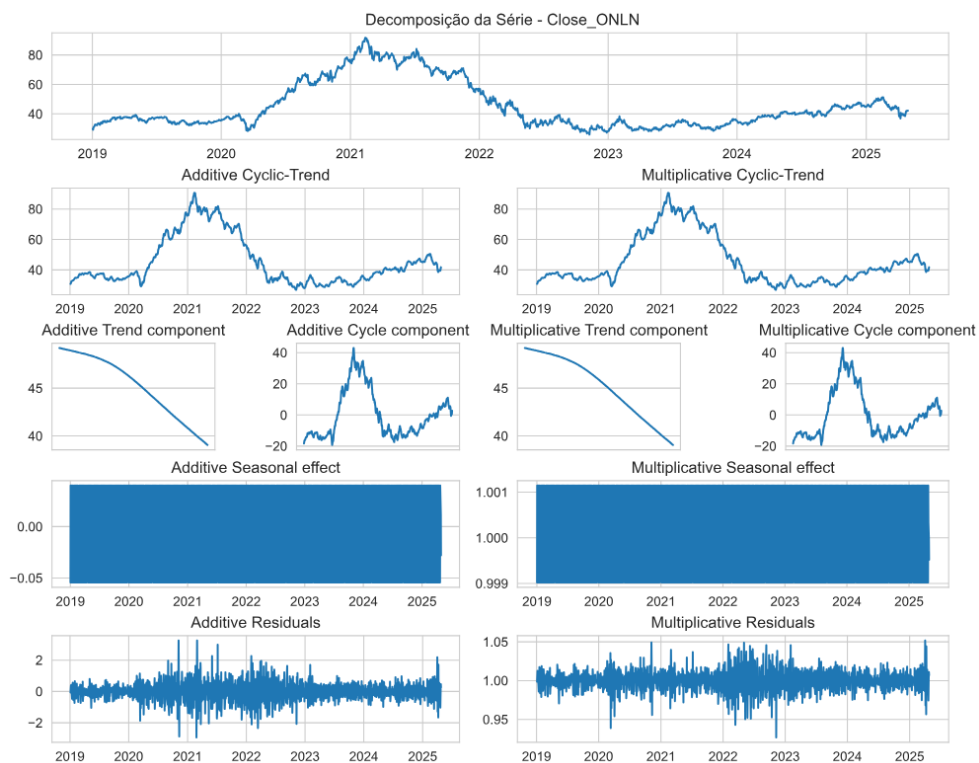
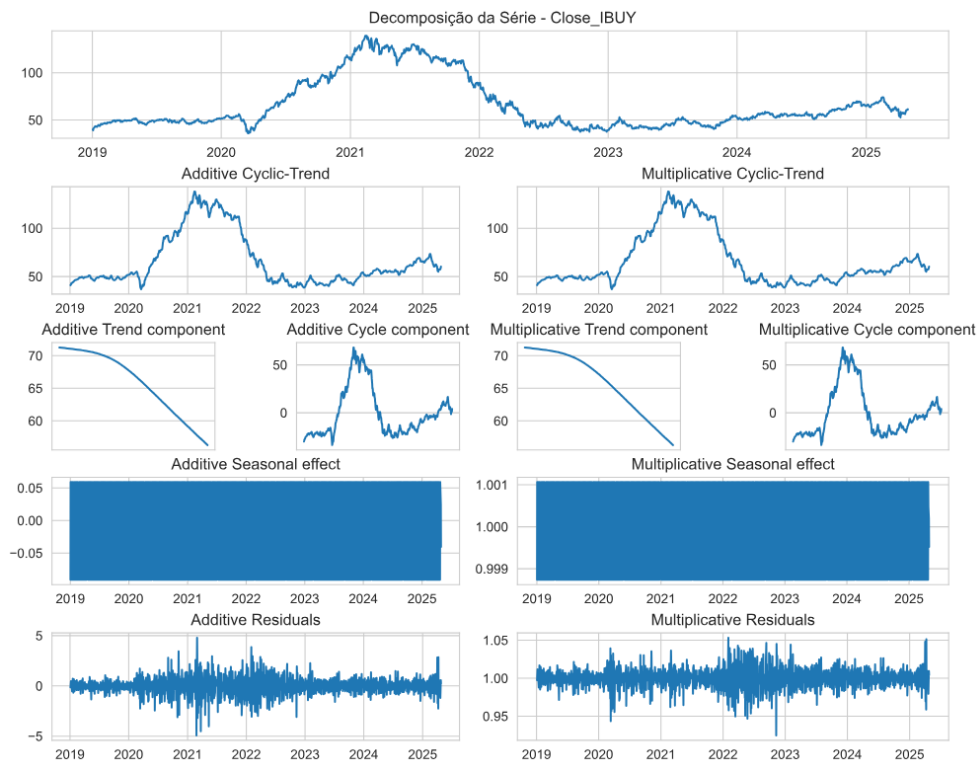
## Anexo F. Funções de Autocorrelação das Séries Temporais





## Anexo G. Decomposição das séries temporais

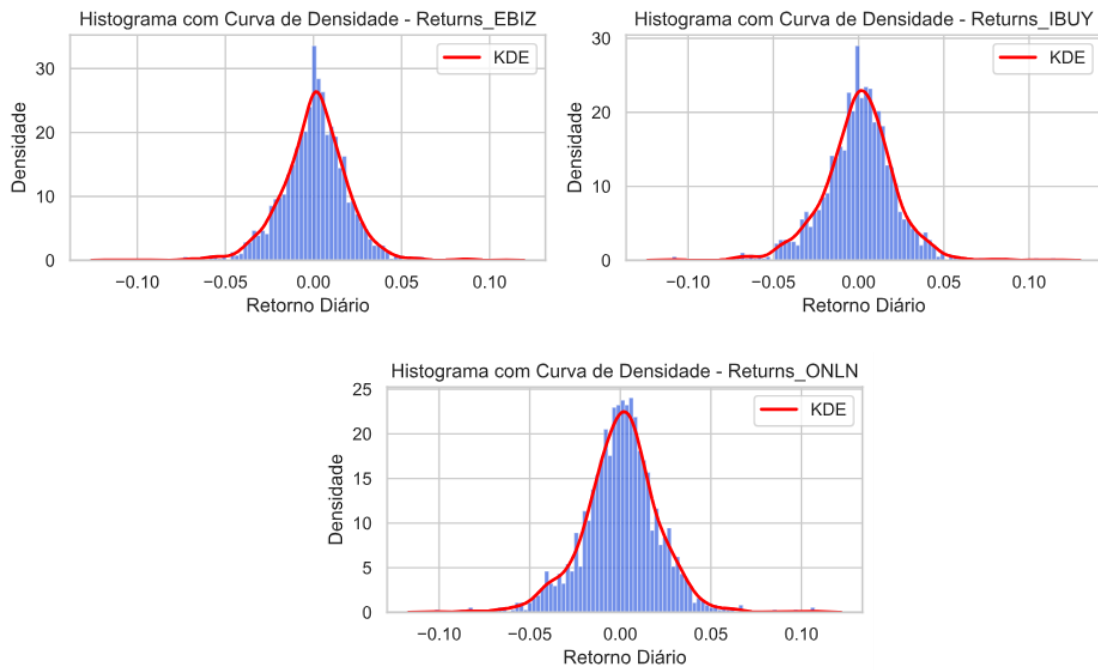




## Anexo H. Avaliação do Risco associado aos ETF

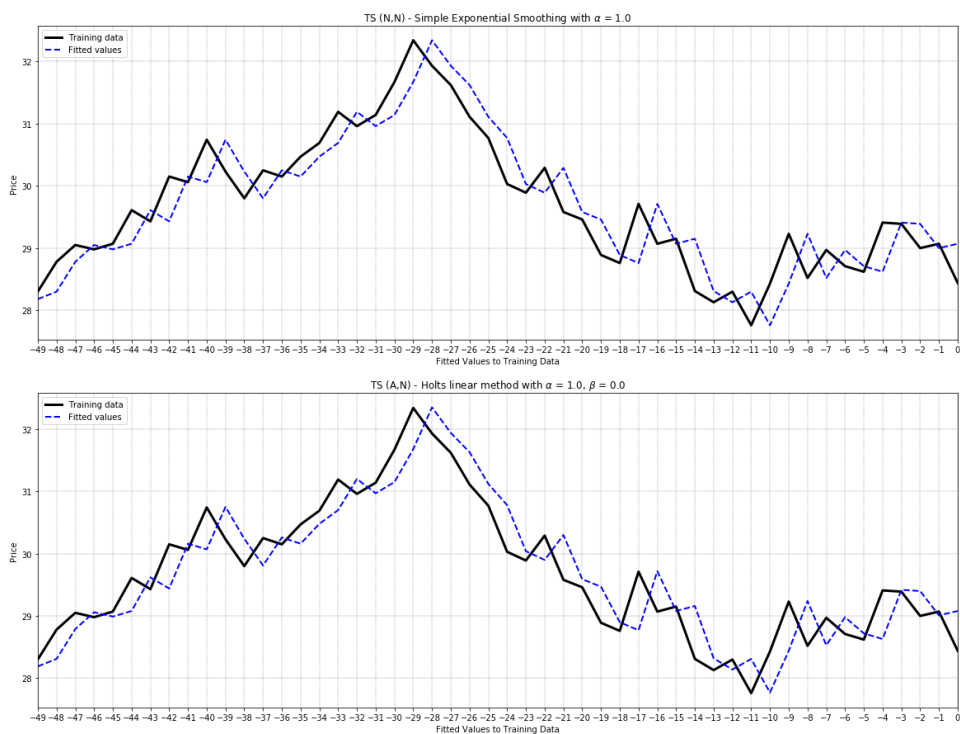
	Retorno Anualizado (%)	Volatilidade Anualizada (%)	Sharpe Ratio	Skewness
<b>Retornos EBIZ</b>	11.46	29.92	0.38	-0.13
<b>Retornos IBUY</b>	6.78	33.26	0.20	-0.15
<b>Retornos ONLN</b>	5.47	33.29	0.16	-0.09


## Anexo I. Histogramas e curvas de densidade dos retornos






## Anexo J. Adequação dos modelos Clássicos aos dados de Treino

### (i) ETF EBIZ








**(ii) ETF IBUY**

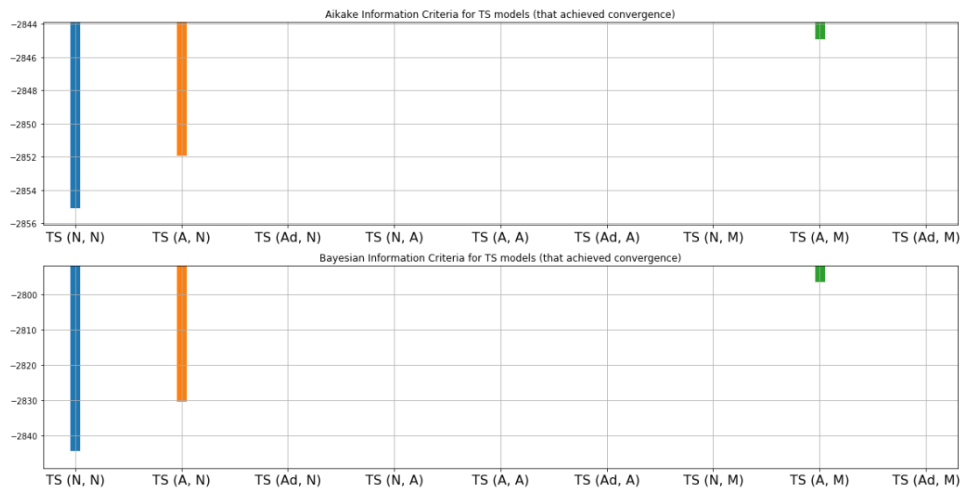


### (iii)ETF ONLY

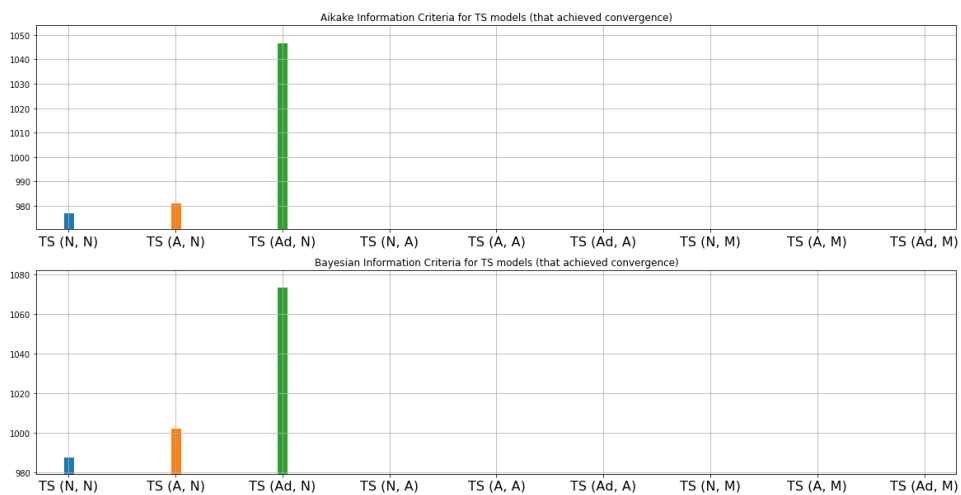


**Anexo K. Seleção dos modelos - Akaike Information Criteria (AIC) e Bayesian Information Criteria (BIC).**


**(i) ETF EBIZ**



**(ii) ETF IBUY**

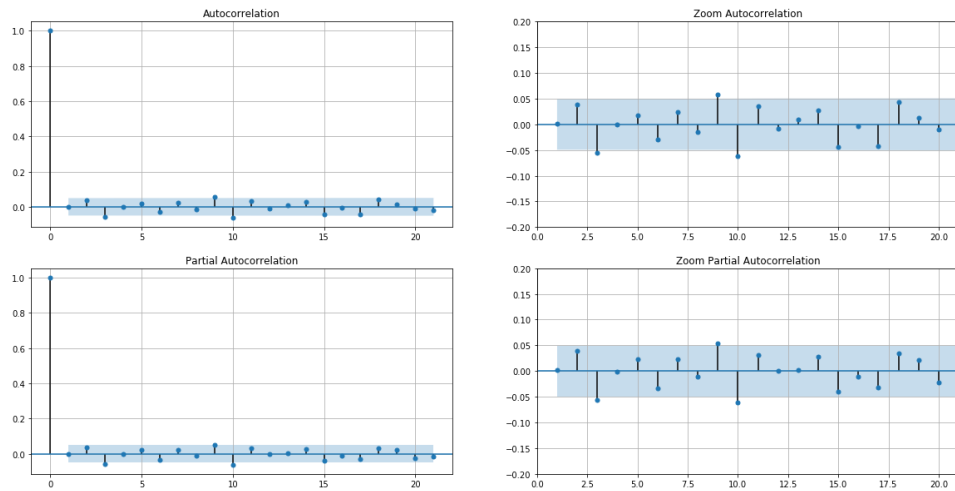


**(iii) ETF ONLN**

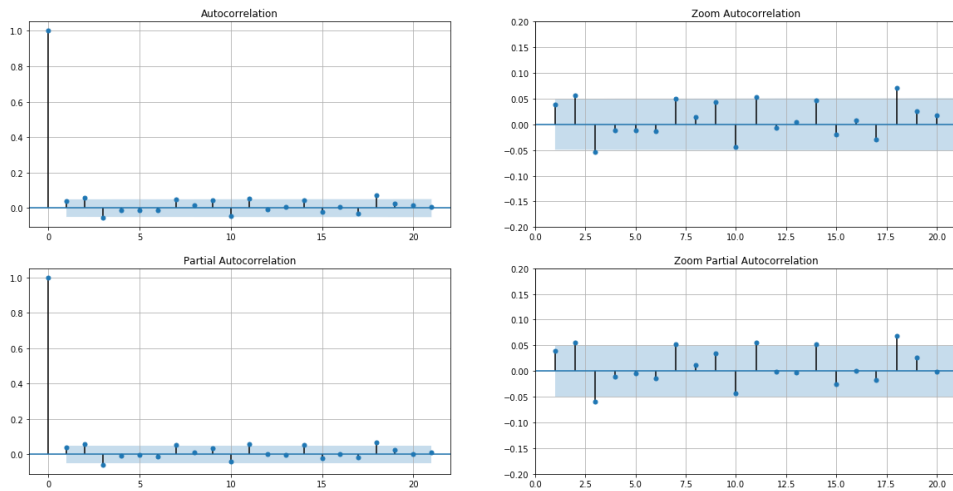


## Anexo L. Análise da Correlação dos Resíduos

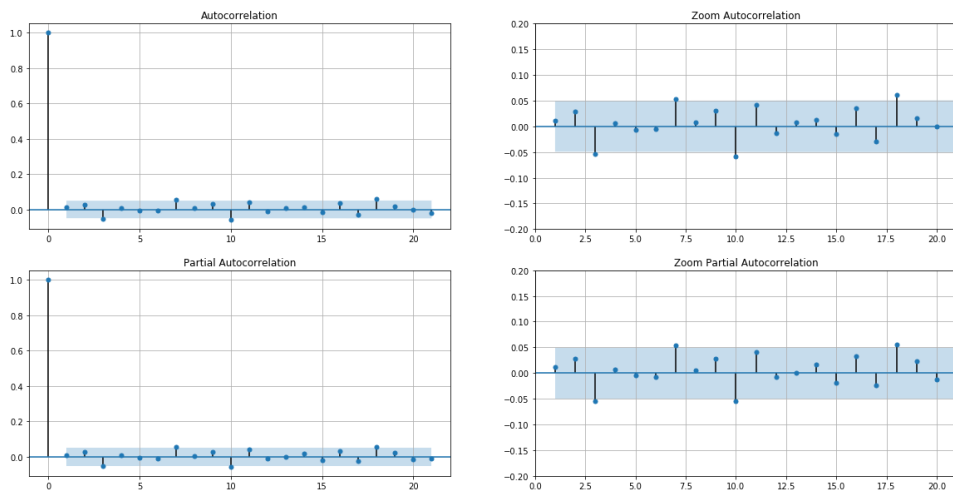
### (i) ETF EBIZ



### (ii) ETF IBUY



### (iii) ETF ONLN



## Anexo M. Adequação dos modelos de *Machine Learning* aos dados de Treino

EBIZ	SVR 1 - 1 lag	SVR 2 - 1 lag	SVR 3 - 1 lag	SVR 1 - 5 lags	SVR 2 - 5 lags	SVR 3 - 5 lags
	C = 1; $\epsilon = 0.001$	C = 100; $\epsilon = 0.001$	C = 10; $\epsilon = 0.01$	C = 1; $\epsilon = 0.001$	C = 100; $\epsilon = 0.001$	C = 10; $\epsilon = 0.01$
MAE	0.3002	0.2994	0.2997	0.3016	0.2977	0.2999
MAPE (%)	1.365%	1.362%	1.363%	1.370%	1.355%	1.362%

IBUY	SVR 1 - 1 lag	SVR 2 - 1 lag	SVR 3 - 1 lag	SVR 1 - 5 lags	SVR 2 - 5 lags	SVR 3 - 5 lags
	C = 1; $\epsilon = 0.001$	C = 100; $\epsilon = 0.001$	C = 10; $\epsilon = 0.01$	C = 1; $\epsilon = 0.001$	C = 100; $\epsilon = 0.01$	C = 10; $\epsilon = 0.01$
MAE	0.9858	0.9824	0.9849	0.9921	0.9816	0.9832
MAPE (%)	1.539%	1.533%	1.538%	1.547%	1.531%	1.534%

ONLN	SVR 1 - 1 lag	SVR 2 - 1 lag	SVR 3 - 1 lag	SVR 1 - 5 lags	SVR 2 - 5 lags	SVR 3 - 5 lags
	C = 1; $\epsilon = 0.001$	C = 100; $\epsilon = 0.001$	C = 10; $\epsilon = 0.01$	C = 1; $\epsilon = 0.001$	C = 100; $\epsilon = 0.01$	C = 1000; $\epsilon = 0.01$
MAE	0.6841	0.6849	0.6847	0.6880	0.6790	0.6768
MAPE (%)	1.546%	1.548%	1.548%	1.552%	1.534%	1.530%

## Anexo N. Representação gráfica do ajustamento dos modelos à amostra de Treino

### (i) ETF EBIZ



## (ii) ETF IBUY



## (iii) ETF ONLN

