



UNIVERSIDADE CATÓLICA PORTUGUESA

Análise de padrões  
comportamentais na entropia de  
mercado, comparando modelos  
de base linear e não linear

Miguel da Costa Ricon Ferraz



UNIVERSIDADE CATÓLICA PORTUGUESA

# Análise de padrões comportamentais na entropia de mercado, comparando modelos de base linear e não linear

Trabalho Final na modalidade de Projeto  
apresentado à Universidade Católica Portuguesa  
para obtenção do grau de mestre em finanças

por

Miguel da Costa Ricon Ferraz

sob orientação de  
Professor Doutor Paulo Alves

Universidade Católica do Porto, Faculdade da Economia e Gestão  
abril de 2023



# Agradecimentos

Esta dissertação é o produto do meu esforço, dedicação e, acima de tudo, do apoio das pessoas que me acompanharam ao longo do meu percurso. Sem elas, este não teria o mesmo significado. Desta forma, não posso deixar de as enumerar.

Aos meus avós, aos meus pais, e ao meu irmão, Henrique, aos quais não tenho palavras para descrever o meu sentimento de gratidão.

Ao Professor Doutor Paulo Alves por toda a disponibilidade, simpatia, pela passagem de conhecimentos e pelos comentários relevantes que fez ao meu trabalho.

Sinto-me honrado por ter realizado a minha dissertação com o Banco Carregosa, uma instituição que representa os mais elevados valores e padrões de excelência. Esta instituição tem sido a base da minha educação e do meu crescimento profissional, e estou grato pelas oportunidades que me proporcionou. Deixo aqui, um agradecimento especial aos elementos do departamento de investimentos do Banco Carregosa por todo o apoio facultado.

Por fim, gostaria de agradecer ao meu mentor e amigo, Mário Carvalho Fernandes, a quem dedico este trabalho, pelo acompanhamento próximo que deu à sua execução e pela confiança que sempre depositou em mim.

“The only time success comes before work is in the dictionary.” – Harvey Spectre – “Suits”.



# Resumo

Numa primeira abordagem, o título desta investigação pode ser interpretado como uma contradição. Isto porque, o conceito de entropia, devido à sua relação de proximidade com o caos, pode ser visto não só como a imprevisibilidade do mercado, como também, pela distorção da informação, e por este motivo não ser possível encontrar padrões. No entanto, esta investigação questiona se os mercados financeiros e a economia real não são simplesmente sistemas caóticos, ou, sistemas caóticos com uma vertente comportamental de maior preponderância em *timeframes* mais curtos. Ao longo deste trabalho vão ser examinados todos os conceitos incluídos no título, bem como outros que irão conferir uma perspetiva coesa e válida através uma revisão bibliográfica relevante. Esta dissertação passa pela conciliação da teoria económica relativa aos mercados financeiros com o campo da engenharia computacional. Este trabalho foca-se na capacidade de previsão das ferramentas de inteligência artificial aplicadas ao mercado cambial, com o apoio da análise técnica. O âmbito deste estudo compreende a comparação da capacidade previsional de modelos lineares face aos não lineares. As teorias clássicas, associadas aos modelos lineares, pretendem embelezar as relações entre os fatores do mundo real, para que estas fiquem ao alcance da compreensão humana. Assim, com as fortes críticas à teoria clássica, nasce o interesse pela modelação não linear que alcança um poder previsional superior, como é apurado nos resultados deste estudo. Como última nota, é de salientar que todos os algoritmos utilizados neste estudo são produto do autor.

Palavras-chave: Forex; ARIMA; DNN.

Número de palavras: 9962



# Abstract

In the first approach, the title of this investigation may appear as a contradiction. The concept of entropy, due to its close relationship with chaos, can be seen as not only the unpredictability of the market, but also the distortion of information, making it impossible to find patterns. This investigation considers that financial markets, and the real economy, are not simply chaotic systems but chaotic systems with a behavioral aspect that is more prominent in shorter timeframes. Throughout this work, all the concepts included in the title, as well as all the others examined, will provide a cohesive and valid perspective through a relevant bibliographical review. This dissertation reconciles economic theory on financial markets with the field of computational engineering, focusing on the predictability of artificial intelligence tools applied to the foreign exchange market, with the support of technical analysis. The scope of this study includes comparing the predictive capacity of linear models against non-linear models. Classical theories, associated with linear models, intend to embellish the relationships between factors in the real world, making them within reach of human understanding. However, with the strong criticism of classical theory, interest in non-linear modeling that achieves superior predictive power has emerged, as verified in the results of this study. Lastly, it is important to note that all algorithms used in this study were written by the author.

Keywords: Forex; ARIMA; DNN.

Number of words: 9962



# Índice

Agradecimentos .....	iv
Resumo .....	vi
Abstract .....	viii
Índice .....	x
Índice de Figuras.....	xiii
Índice de Tabelas .....	xv
Capítulo 1 - Introdução .....	17
Capítulo 2 - Revisão de literatura.....	20
2.1 Teoria financeira.....	20
2.1.1 Teorias da eficiência de mercado.....	20
2.1.2 O Surgimento de novas teorias .....	23
2.1.2.1 Teoria do caos.....	23
2.1.2.2 Teoria das finanças comportamentais .....	25
2.2 Análise Técnica.....	26
2.2.1 Gráfico de velas .....	27
2.2.2 Entropia .....	27
2.3 Forex.....	29
2.3.1 Principais moedas .....	31
2.3.2 Relação com a teoria financeira.....	31
2.4 Modelos de previsão.....	32
2.4.1 Modelos lineares .....	33
2.4.1.1 <i>Random walk</i> .....	33
2.4.1.2 <i>Autoregressive Integrated Moving Average (ARIMA)</i> .....	34
2.4.2 Modelos não lineares .....	35
2.4.2.1 <i>Deep Neural Networks</i> .....	35
2.4.2.1.1 Seleção dos <i>inputs</i> e pré-processamento.....	37
2.4.2.1.2 Processo de treino das DNN .....	38
2.4.2.2 Tendências .....	41
2.4.3 Medidas de <i>performance</i> .....	41
Capítulo 3 - Metodologia.....	43
3.1    Objetivos e enquadramento .....	43
3.1.1 Enquadramento da investigação .....	44
3.1.1.1. Ambiente da investigação .....	44
3.1.1.2. Descrição dos dados.....	46

3.1.1.3 Recolha de dados .....	48
3.1.1.4. Pré-processamento .....	48
3.1.1.4.1. Limpeza dos dados.....	48
3.1.1.4.2. Seleção dos pares cambiais.....	49
3.1.1.4.3. Transformação dos dados .....	50
3.1.1.4.4. Separação dos dados em sets de treino e teste .....	50
3.1.2. Modelação linear .....	51
3.1.2.1 Testes à estacionariedade .....	51
3.1.2.2. Modelo ARIMA .....	53
3.1.3. Modelação não linear (DNN) .....	55
3.2 Resultados .....	58
Capítulo 4 - Conclusão .....	60
Bibliografia.....	63



# Índice de Figuras

<b>Figura 1:</b> esquema de uma DNN .....	37
<b>Figura 2:</b> fluxograma da metodologia .....	45
<b>Figura 3:</b> <i>scatter plot</i> dos retornos dos pares cambiais selecionados.....	52
<b>Figura 4:</b> estrutura da DNN utilizada.....	56
<b>Figura 5:</b> <i>scoring history</i> das DNNs criadas .....	57



# Índice de Tabelas

<b>Tabela 1:</b> principais moedas do mercado cambial.....	31
<b>Tabela 2:</b> seleção dos pares cambiais.....	50
<b>Tabela 3:</b> R <i>output</i> - <i>Augmented Dickey-Fuller Test</i> .....	51
<b>Tabela 4:</b> R <i>output</i> - “ <i>auto.arima()</i> ” .....	54
<b>Tabela 5:</b> R <i>output</i> - testes aos pressupostos .....	55
<b>Tabela 6:</b> R <i>output</i> - resultados dos modelos .....	58



# Capítulo 1 - Introdução

Ao longo dos anos o mercado cambial tem sido repetidamente referido como aquele mais próximo da noção académica de “mercado perfeito”. As principais características que contribuem para essa ideia são a standardização do produto (*fiat currencies*), a dimensão do mercado que impossibilita que uma entidade detenha uma grande participação no mesmo, o facto de as barreiras à entrada do mercado serem poucas ou inexistentes, a liquidez, e, por fim, a quantidade e qualidade da informação pública. O mercado de Forex é altamente imprevisível, devido à elevada complexidade das relações entre fatores integrantes. Isto compreende a definição de mercado eficiente mencionada por Fama (1965a).

Em termos gerais, num mercado eficiente, os investidores obtêm retornos que refletem os custos de capital ajustados a um certo nível de risco (Zunino et al., 2009). Posto isto podemos assumir que os investidores têm à sua disposição ativos cujo preço de mercado reflete toda a informação disponível, e por consequência, as suas decisões serão fundamentadas num mercado sem distorções, onde os preços estão corretamente ajustados ao risco.

Os modelos económicos da teoria financeira clássica passam pela exposição de um agente representativo da sociedade como um todo, pela proposta de um equilíbrio como o estado natural do sistema económico, e por fim, pela caracterização das relações que este compreende através da linearização, um

método matemático “elegante” devido à sua simplicidade e coesão. Este é o panorama que faz dos modelos clássicos uma formulação fictícia, tão atrativa como distante da realidade. O espectro da sua utilização não se enquadra de forma perfeita no mundo real, e é a partir de raciocínios como este que surgiram novas teorias, como a teoria do caos e a teoria das finanças comportamentais. Estas teorias são a base fundamental dos modelos que adotam técnicas matemáticas mais avançadas, ajustadas à realidade dos fenómenos económicos.

A análise técnica desempenha um papel central devido à natureza quantitativa dos dados e da metodologia aplicada nesta investigação. A capacidade previsional do mercado Forex foi amplamente estudada. A atenção dos estudos mais recentes remete para o acréscimo o poder previsional inerente aos modelos de inteligência artificial (IA). Estes modelos têm a capacidade de assimilar a não linearidade do mercado, ao contrário dos modelos estatísticos e econométricos, e são capazes de descrever padrões comportamentais entre os fatores influentes. Assim, este trabalho estabelece uma comparação entre a capacidade de previsão dos modelos lineares e não lineares, no que toca à minimização do erro das previsões, quando aplicados ao mercado cambial. Esta dissertação procura conferir suporte empírico à revisão de literatura abordada.

Este trabalho começa com uma revisão dos principais conceitos da teoria financeira, do mercado cambial, da análise técnica e dos modelos utilizados. Segue-se a modelação e análise dos resultados, e por fim, será feita uma avaliação dos resultados obtidos, tendo em conta os conceitos inicialmente abordados, bem como, um resumo das principais conclusões.

É importante informar que este trabalho de investigação foi realizado no âmbito de uma tese de mestrado de finanças e que a área financeira será o seu

foco. A ciência computacional, associada ao estudo, acaba por apresentar um papel secundário, no entanto fundamental.

## Capítulo 2 - Revisão de literatura

### 2.1 Teoria financeira

#### 2.1.1 Teorias da eficiência de mercado

Num mercado eficiente dá-se um processamento eficiente da informação, que acaba por concentrar toda a informação disponível no preço do ativo. Assim, o preço cotado é a melhor estimativa do valor real do ativo. À medida que o fluxo de informação atinge o mercado, na forma de notícias que pela sua definição são imprevisíveis, a perspectiva dos investidores em relação ao estado atual e desempenho futuro do ativo vai-se alterando. Como consequência, o mercado incorpora, instantaneamente, as expectativas dos investidores. E desta forma o conceito de mercado eficiente resume-se à incapacidade de os investidores gerarem lucros superiores aos retornos médios anexados a um nível de risco correspondente.

A visão que era amplamente assumida anteriormente à Hipótese da Eficiência de Mercado afirmava que seria possível prever os preços de mercado utilizando ferramentas provenientes da análise técnica. No entanto, a hipótese da *random walk* foi pela primeira vez abordada por Bachelier, em 1900, no seu trabalho “The Theory of Speculation” (Bachelier, 1900). Neste artigo, o autor descreve uma série

temporal baseada nas alterações do preço onde os movimentos futuros não seguem qualquer padrão baseado na série que os antecede, sem referir a noção de eficiência de mercado.

É apenas a partir do início dos anos 60 que se formulam os primeiros estudos empíricos que constroem a evidência a favor da eficiência de mercado. Neste contexto, nasce uma dualidade, que permanece na atualidade, entre o conceito de os preços dos ativos refletirem fundamentos económicos e o conceito de as alterações dos preços de mercado se apresentarem de forma aleatória (Delcey, 2019). Fama e Samuelson realizaram os estudos que criaram esta dualidade e deram origem à construção teórica da HEM (Fama, 1965a; Samuelson, 1965).

Samuelson (1965) propôs o modelo de *martingale* como uma alternativa ao *random walk* para descrever o comportamento aleatório do mercado. Neste sentido, caso uma série temporal se aproxime de um modelo de *martingale*, que por sua vez subentende o preço do contrato futuro como a melhor estimativa para o preço de amanhã, tendo em conta a informação disponível, não é possível prever as alterações de hoje para amanhã, fazendo da análise técnica um método inutilizável. No seu trabalho o termo “eficiência” não está presente, a flutuação aleatória dos preços é atribuída, exclusivamente, à competição que vigora entre os investidores (teoria do equilíbrio geral) (Samuelson, 1964). É excluída qualquer relação com o valor fundamental, não sendo o preço uma boa estimativa deste último.

Fama é o primeiro a abordar a noção de mercado eficiente (Fama, 1965a). O autor aponta a *random walk* como uma boa aproximação dos movimentos evidenciados, no entanto, não passa de uma “aproximação”, afirmando que não é possível encontrarmos uma série temporal dotada de independência perfeita.

Fama (1965a) dá um passo em frente face à investigação realizada até à data, com a introdução de dois tipos de *traders* sofisticados: os fundamentalistas estimam a discrepância entre o preço de mercado e o preço fundamental, os técnicos focam-se nas dependências geradas por essas discrepâncias. No mesmo ano, Fama (1965b) reestrutura a HEM, quanto à interpretação da relação entre valor fundamental e o preço de mercado. O conceito de *trader* sofisticado é substituído por agente racional cujo principal objetivo é a maximização do lucro individual, o que gera competição no mercado e por consequência aproxima o preço de mercado do valor fundamental, fazendo do preço cotado uma boa estimativa do valor intrínseco.

Ao longo dos anos, Fama foi adaptando a sua visão sobre os mercados e, ao contrário de Samuelson, foi-se afastando do debate sobre o carácter aleatório das variações do preço. Passando o foco da eficiência do mercado para a forma como o mercado absorve e deixa transparecer a informação disponível. Fama (1970) formalizou pela 1ª vez a base da teoria económica convencional. Neste trabalho foram descritas 3 formas da eficiência de mercado<sup>1</sup> e o modelo de *martingale*, anteriormente mencionado por Samuelson, substitui o *random walk*, pelo facto de ser menos restritivo. A última reformulação da HEM foi apresentada por Fama (1976) e foca-se nas expectativas racionais.

Samuelson e Fama têm em conta pressupostos semelhantes: a competição no mercado, o facto de a informação ser acessível a todos os investidores e apontar o comportamento racional dos investidores como a causa das flutuações aleatórias. No entanto, enquanto Fama restringe a aleatoriedade dos preços a um comportamento determinístico, Samuelson descreve-a como um fenómeno em si

---

<sup>1</sup> A “*Weak form*” onde os preços refletem toda a informação contida na serie temporal. A “*Semi-strong form*” onde os preços se ajustam e refletem toda a informação publica. A “*Strong form*” onde o mercado reflete toda a informação, publica e privada.

(Delcey, 2019). De um lado, encontra-se a aleatoriedade das alterações dos preços, do outro lado a precisão dos preços.

### 2.1.2 O Surgimento de novas teorias

Os modelos da teoria financeira convencional descrevem o sistema económico com o pressuposto de um agente de mercado individual e racional. Este pressuposto ignora a heterogeneidade das interações dos intervenientes na realidade. Para além disto, a complexidade do comportamento dos agentes é impossível de ser traduzida por modelos lineares.

A partir de meados dos anos 70, a HEM começa a ser posta em causa por vários autores que acreditavam na previsibilidade dos preços de forma parcial, devido à componente comportamental dos investidores. Assim surge uma necessidade de integrar a dinâmica das interações entre os agentes de mercado que se adaptam às reações do ambiente que os rodeia (que em parte são o *feedback* das suas intervenções motivadas pela inovação), sem a presença de pressupostos que afastem os modelos económicos da realidade (Faggini & Parziale, 2012). A teoria económica sofreu alterações devido aos avanços científicos e tecnológicos. Durante os anos 80, com o aumento dos estudos empíricos, nasceram teorias alternativas à HEM.

#### 2.1.2.1 Teoria do caos

O interesse académico na teoria do caos surge nos anos 80 e parte do aumento da instabilidade e da aleatoriedade nos mercados. O conceito de caos é por vezes equivocado com a distorção da informação que proporciona decisões imprudentes por parte dos investidores (Faggini & Parziale, 2012). No entanto, o caos advém do crescimento das inovações no mercado financeiro que dão origem à sua transformação.

Segundo esta teoria, o ambiente que nos rodeia, assim como o mercado financeiro, apresenta uma ordem aleatória, não linear. Nos sistemas não lineares, as variáveis-chave seguem um caminho aleatório, que é gerado por um processo caótico e determinístico, subentendendo a impossibilidade de prever os valores futuros das variáveis que o modelo engloba. Este atributo aparenta ser semelhante à descrição de uma caminhada aleatória, no entanto o seu motivo é explicado pelo atributo seguinte. O caos provém da dependência à sensibilidade das condições iniciais dos sistemas dinâmicos determinísticos (caóticos) e da agregação das expectativas e ações (racionais e irracionais) dos participantes de mercado, que se traduz em comportamentos imprevisíveis de longo prazo, estando associado a eventos negativos e positivos. Este atributo é por vezes descrito como o “efeito borboleta”, já que pequenas alterações na situação inicial poderão dar origem a fenómenos bastante distintos e a caminhos alternativos na perpetuidade (Federici & Gandolfo, 2014).

A teoria financeira tradicional não tem em conta as dinâmicas não lineares e quaisquer desvios do equilíbrio serão vistos como anomalias. Esta é criticada pela presença de pressupostos cujo objetivo passa pela manipulação matemática de conveniência e não pela aproximação à realidade. Por outro lado, a teoria do caos é baseada nas tendências não lineares do sistema, abrindo portas à compreensão da estrutura da imprevisibilidade, assumindo o sistema financeiro como complexo e composto pela interação estruturada de subsistemas onde a instabilidade resulta da frequência de inovação (Klioutchnikov, Sigova & Beizerov, 2017). Assim, o desenvolvimento dos mercados exige um acompanhamento da complexidade dos modelos e processos matemáticos (inovação tecnológica). Contudo, as previsões não alcançam um grau de precisão satisfatório. Para tal seria necessário medir o valor das variáveis na condição

inicial à escala infinitesimal, devido à sua sensibilidade face a pequenos ruídos de mercado. São inúmeros os autores que abordaram esta teoria (Chen, 1988; Davis, Hands, & Mäki, 1998; Faggini & Parziale, 2012; Hsieh, 1991; Klioutchnikov, Sigova & Beizerov, 2017). Existem métricas que possibilitam identificar a presença de caos num sistema. Uma delas é a entropia, que foi definida na secção 2.2.2.

#### 2.1.2.2 Teoria das finanças comportamentais

A teoria das finanças comportamentais nasce do estudo de Kahneman e de Tversky. Estes apontam o facto de os investidores descartarem a importância dos eventos possíveis face aos mais prováveis, sendo esta a base da teoria da perspectiva (Kahneman & Tversky, 1979). Mais tarde, Thaler (1999) faz a ligação entre esta teoria e o mercado financeiro. Por fim, Shiller (2003) evidencia que apesar de a HEM ser aparentemente viável a nível microeconómico, não o é a nível macro. Estes autores são considerados os fundadores da teoria das finanças comportamentais (Kumar & Goyal, 2016).

Esta crítica aos modelos racionais (modelos que assumem a existência de um agente económico racional). Num ponto de vista geral, os fatores psicológicos afetam diretamente a tomada de decisão e este aspeto tem vindo a ser estudado a par da noção de mercado eficiente que serve de controlo.

O conceito de bolha de mercado subentende que um grupo de investidores, sobre os quais recai uma racionalidade limitada por fatores psicológicos, poderá ter uma grande influência no mercado. Assim, Barberis e Thaler (2003) derivam as finanças comportamentais de dois fatores principais: da psicologia cognitiva e dos limites da arbitragem.

Neste sentido, os resultados de vários estudos mostram a presença destes fatores psicológicos nos processos de tomada de decisão, associados aos mercados financeiros, e por este motivo colocam de parte o conceito de investidor racional (Bloomfield & Hales, 2002; Genesove & Mayer, 2001; Hong, Lim & Stein, 2000; Kumar & Goyal, 2016; Lee, Shleifer & Thaler, 1991; Odean, 1998).

O campo das finanças comportamentais é uma peça importante na compreensão dos mercados financeiros. E é vista por muitos acadêmicos como o substituto da teoria financeira convencional que carece de uma explicação comportamental, sem a descartar dentro de certos limites (Olsen, 1998).

## 2.2 Análise Técnica

Existem dois tipos distintos de análise: a fundamental e a técnica. A análise fundamental foca-se na percepção de valor intrínseco, baseia-se na percepção de tendências de valor futuro que resultam de diversos fatores e eventos sob análise permanente e sobre os quais é necessário agir rapidamente devido à velocidade de propagação da informação no mercado e partindo do princípio de que não existem efeitos materiais de *inside information* ([www.investopedia.com](http://www.investopedia.com)). No âmbito deste trabalho, como já foi referido, vamos focar-nos na análise técnica, que parte do princípio de que, segundo Fama (1970) todos os dados estudados e analisados no campo da análise fundamental já se encontram refletidos no preço. Contudo, para Shiller (2016) os preços não dependem apenas dos fundamentais, mas também das decisões irracionais dos investidores. Assim, serão explorados conceitos e ferramentas que integrarão o conjunto de *inputs* utilizados neste estudo.

### 2.2.1 Gráfico de velas

A análise técnica tem por base a análise dos movimentos do preço ao longo do tempo. Num gráfico de velas, estas são desenhadas para um certo período (semanais, diárias, de uma hora, etc.). Em cada vela observamos o preço de abertura, fecho, o mais elevado e o mais baixo no período (Pring, 2014).

Nesta perspetiva, um mês com 22 dias de transação pode ser representado por uma vela mensal, 22 velas diárias, ou 528 velas de uma hora. À medida que vão sendo registados novos preços dá-se a formação de novas velas e por sua vez a formação de padrões de mercado. Assim como Pring (2014) e Murphy (1999) outros investidores acreditam na capacidade de previsão das alterações do preço, partindo do princípio de que estes padrões se tratam de padrões comportamentais e que por este motivo se irão repetir no futuro. Isto porque os padrões comportamentais partem dos investidores para o mercado e não o contrário, já que os ativos financeiros não evidenciam comportamentos inatos (Shiller, 2016). Estes padrões traduzem-se em sinais para o analista, isto é, podem ser traduzidos numa indicação de compra, venda ou neutro. No entanto, a descoberta destes padrões de mercado não é tão clara como possa parecer já que muitos não são desenhados de forma perfeita e em alguns dos casos não chegam a ser completados (Pring, 2014).

Assim, o objetivo final deste trabalho passará pela integração dos 4 preços representativos de cada vela num conjunto de *inputs* utilizados com o objetivo de encontrar padrões não lineares nas séries temporais que vão ser estudadas.

### 2.2.2 Entropia

Apesar de o conceito de entropia e caos estarem relacionados, estes diferem. Enquanto o caos representa uma dependência não linear das condições iniciais,

ou seja, contém uma relação implícita com o percurso das variáveis (Klioutchnikov, Sigova & Beizerov, 2017). A entropia descreve um estado e não está relacionada com a evolução do sistema, esta é uma medida de desordem num ponto temporal (Shannon, 1948). O valor da entropia resulta de uma “função estado” cujo valor em si não tem significado. O que é relevante é a alteração deste valor entre dois momentos, antes e após alterações do contexto de mercado. Assim com esta medida é apenas possível determinar o valor inicial e final sem considerar o caminho percorrido entre os dois. No entanto, isto não invalida a sua utilização, antes pelo contrário. Num sistema isolado a entropia não pode diminuir, no entanto, como o mercado é definido como uma estrutura dissipativa, onde as trocas de informação com a envolvente (economia real) são incessantes (Prigogine & Stengers, 1984). Segundo Prigogine e Stengers (1984), num sistema caótico não é possível prever o estado final, no entanto, se já o conhecermos (o que à partida supera as bases da teoria do caos), a entropia permite-nos supor que o caminho não importa desde que aquele seja o resultado que esperamos.

A entropia apresentada por Shannon (1948) é uma métrica de incerteza. Apontada como alternativa ao desvio padrão, a entropia é capaz de capturar a incerteza e desordem numa série temporal sem impor restrições à distribuição probabilística teórica (Bentes & Menezes, 2012; Dionisio, Menezes & Mendes, 2006). Esta métrica caracteriza a incerteza relativa à reação do preço face ao impacto de notícias. Por exemplo, quando uma notícia impacta o mercado, com uma magnitude suficiente para gerar um comportamento coletivo direcional, a entropia de mercado é reduzida (Pele, Lazar & Dufour, 2017).

A entropia de Shannon (1948) é representada pela seguinte fórmula:

$$H(x) = - \sum_{x=i}^n [ p_i(x) \text{Log}_2(p_i(x)) ]$$

Para aplicar esta fórmula aos retornos de um ativo é importante definir um conjunto de intervalos onde estes retornos se possam enquadrar, obtendo assim a frequência dos retornos. Ao fazer isto estamos a transformar um variável contínua em discreta para que a entropia possa ser usada na base de um somatório e não um diferencial usado em variáveis contínuas (Xiong, Faes & Ivanov, 2017). Assim, a variável  $p_i$  é definida como a probabilidade associada a cada um dos intervalos definidos.  $H(x)$  pode variar entre 0 e 1. Segundo Shannon (1948), o nível de entropia é máximo quando todos os eventos possíveis têm a mesma probabilidade de ocorrência (distribuição uniforme) e mínimo no caso de um evento ser certo. Ou seja, quanto maior o número de eventos possíveis e mais próximas as suas probabilidades de ocorrência, maior a entropia (Corsetti, Lafarguette & Mehl, 2019).

## 2.3 Forex

O mercado *Foreign Exchange* (mercado cambial ou Forex) é um mercado global descentralizado, que possibilita a conversão de moedas com base no seu valor relativo. As taxas de câmbio oscilam consoante uma variedade de fatores, como condições económicas, políticas governamentais e monetárias, fatores psicológicos e eventos macroeconómicos. A elevada complexidade das relações destes fatores traduz-se no nível da dificuldade de previsão das taxas de câmbio (Archer, 2008).

De acordo com Archer (2008), o mercado cambial cobre todos os países e territórios pois opera numa rede de bancos, empresas e indivíduos, sem uma localização física ou uma bolsa central, o que permite transacionar durante 24 horas por dia, durante os dias úteis, passando por todos os fusos horários em todos os centros financeiros respetivos. Archer (2008) menciona que este mercado é regulado pelos próprios intervenientes que se regem pela lei do preço único, que está associada a um mercado competitivo onde a regulação é baixa devido à eficiência do mercado.

Segundo as mais recentes estatísticas do Bank of International Settlements (BIS), este mercado ultrapassou a marca dos 6,6 biliões de dólares diários em transações, em 2019 (Schrimpf & Sushko, 2019). Atualmente o tipo de ativo financeiro com maior representação é o FX *swap* com cerca de 3 biliões dólares e o centro financeiro que detém o maior volume de transações é o de Londres com uma representação superior a 50%, que é mantida há mais de uma década. O relatório mais recente do BIS, realizado em 2019, afirma que o volume de transações neste mercado continua a ser dominado pelas instituições financeiras, com uma tendência crescente para os consumidores ligados a empresas financeiras à parte dos *dealers* e uma tendência decrescente para os *dealers* bem como para clientes não financeiros.

Apesar de representar uma margem muito pequena, durante os últimos anos, temos vindo a verificar um crescimento do sector de retalho no Forex, sendo que a continuação desta tendência é inevitável (Schrimpf & Sushko, 2019). Mas nem sempre foi assim, durante muito tempo este mercado foi ignorado pelos investidores especulativos e agora encontra-se no centro das atenções devido a características únicas que agradam aos investidores de retalho, com a possibilidade de encontrar uma maior rentabilidade. Uma das características que

torna este mercado tão atrativo para certos *traders* é o uso de alavancagem que permite aos *traders* alcançar elevados volumes de transação com um nível baixo de capital Archer (2008).

### 2.3.1 Principais moedas

Símbolo	País	Moeda
USD	EUA	Dólar
EUR	Zona Euro	Euro
JPY	Japão	Yen
GBP	Reino Unido	Libra
CHF	Suíça	Franco suíço
CAD	Canadá	Dólar canadiano
AUD	Austrália	Dólar australiano
NZD	Nova Zelândia	Dólar neozelandês

**Tabela 1:** principais moedas do mercado cambial

### 2.3.2 Relação com a teoria financeira

Certas dinâmicas do mercado Forex podem ser estudadas e explicadas pela teoria financeira. A teoria do caos, através do “efeito borboleta”, permite-nos entender como é que eventos de pequena dimensão, que passam despercebidos na forma de ruído, podem ter um impacto de elevada magnitude no mercado (Federici & Gandolfo, 2014). Ao mesmo tempo as finanças comportamentais também têm poder explicativo no que toca à análise do mercado Forex. O *herding behavior* que ocorre quando uma grande parte dos agentes de mercado seguem o mesmo raciocínio, e a falta de decisões independentes provoca sobre ou subvalorizações de ativos (Rook, 2016). Outro conceito das finanças comportamentais que podemos evidenciar no mercado cambial é o “efeito de

ancoragem”, que se baseia no facto de o raciocínio dos agentes de mercado ficar ancorado a uma certa informação que os impede de considerar outras possibilidades ou até mesmo subestimar o risco em que estão a incorrer (Furnham & Boo, 2011).

Através da compreensão dos conceitos básicos da teoria do caos e da teoria das finanças comportamentais, e a sua posterior aplicação ao mercado cambial, apercebemo-nos da natureza das dinâmicas do mercado e conseqüentemente da necessidade de utilização de métodos de modelação não lineares (Federici & Gandolfo, 2014).

## 2.4 Modelos de previsão

O objetivo desta secção engloba a apresentação e desenvolvimento teórico dos métodos e modelos utilizados nesta investigação, bem como a revisão das principais tendências no campo da IA.

Como foi analisado, os movimentos de mercado podem ser descritos pela relação entre os agentes e a reação destes aos eventos de mercado Shiller (2016). No entanto, a interação das variáveis, que descrevem estas relações em séries temporais, são de evidência não linear, não sendo assim compatíveis com os modelos convencionais de base linear (ARIMA), dotados de uma interpretação mais simples e acessível à compreensão humana. Esta é uma das características que evidencia a robustez dos modelos de IA, alcançando, assim, outro nível de previsão das séries temporais financeiras (Rundo et al., 2019). Outra vantagem deste tipo de modelos advém da sua robustez que acaba por atenuar o efeito do ruído nas previsões obtidas, em parte devido à vantagem anteriormente exposta,

conseguindo assim ultrapassar barreiras provisionais inerentes aos dados em análise. No entanto, existe uma outra problemática que tem impacto nos dois tipos de modelos, de forma semelhante. Esta advém da teoria financeira e é exposta pela teoria das finanças comportamentais: como a não necessidade de encontrar uma solução ótima.

No artigo de Bartram, Branke e Motahari (2020), do CFA Institute Research Foundation, é feito um enquadramento das novas técnicas e tendências que a IA trouxe para os mercados financeiros, destaca não só o potencial para os sistemas de investimento, que utilizam IA, como também as desvantagens, pelo facto de serem modelos opacos e complexos, o que faz com que sejam difíceis de monitorizar e descortinar, para além de serem muito sensíveis aos dados.

É neste capítulo (e no seguinte) que se procura relacionar (teoricamente) os indicadores técnicos (IT) com as técnicas de IA. Os IT não têm flexibilidade em relação às condições de mercado, já que estes não passam de uma equação, com uma relação constante estabelecida, na qual inúmeros preços são inseridos recorrentemente (Murphy, 1999). Isto não quer dizer que estes indicadores não façam uma boa descrição do estado atual do mercado, mas sim que carecem de poder provisional devido ao facto de descreverem o mercado com informação desfasada. Assim surge a necessidade de conciliar estes dados provenientes da análise técnica com modelos que conseguem explorar relações entre os dados que vão para lá da compreensão humana.

## 2.4.1 Modelos lineares

### 2.4.1.1 *Random walk*

O modelo *random walk* é o modelo matemático que define a previsão de um valor futuro de uma série temporal como um desvio aleatório do valor atual, e é também mencionado como um processo estocástico (Tsay, 2005). Assim como foi mencionado anteriormente, o *random walk* assume que os valores futuros de uma série temporal não podem ser previstos com base nos valores históricos da série e que a melhor estimativa do valor futuro é o valor atual, tal como na teoria financeira convencional (Dupernex, 2007).

A fórmula geral do modelo *random walk* é:

$$y'_t = y_{t-1} + \varepsilon_{t-1}, \quad \varepsilon \sim N(0, \sigma)$$

Assume-se que o termo do erro ( $\varepsilon_{t-1}$ ) é distribuído de forma idêntica e independente (i.i.d.) com média de zero e variância constante.

#### 2.4.1.2 *Autoregressive Integrated Moving Average (ARIMA)*

Os modelos ARIMA são os modelos lineares mais utilizados para prever séries temporais univariadas, devido à sua simplicidade e aceitação pela comunidade acadêmica no que toca ao seu poder previsional (Box, 2013). Este tipo de modelo captura a dependência linear de uma observação, com base nos valores históricos da série temporal. Com isto, é importante introduzir o conceito de estacionariedade. Uma série temporal estacionária é definida por uma série de dados em que as suas propriedades estatísticas não seguem um padrão definido ao longo do tempo, ou seja, as observações registadas não apresentam uma tendência ou sazonalidade ao longo do tempo (Tsay, 2005). Sendo assim, os modelos ARIMA combinam os modelos autoregressivos (AR, parâmetro p) e os modelos de médias móveis (MA, parâmetro q) e diferem dos modelos ARMA porque têm a capacidade de eliminar as variações das séries não estacionárias, através do processamento das diferenças de uma observação face às anteriores

(I, parâmetro d) (Tsay, 2005). Um exemplo da diferença de primeira ordem é o seguinte:

$$y'_t = y_t - y_{t-1}$$

Neste sentido, a fórmula geral do modelo ARIMA (p, d, q) passa a ser:

$$y'_t = c + \sum_{i=1}^p \Phi_i y'_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j}$$

- $\Phi_i \{1, \dots, p\}$ : coeficientes autorregressivos AR(p);
- $\theta_j \{1, \dots, q\}$ : coeficientes de média móvel MA(q);
- $\varepsilon_{t-j}$ : *white noise*  $\approx \sim N(0, \sigma^2)$ ;

## 2.4.2 Modelos não lineares

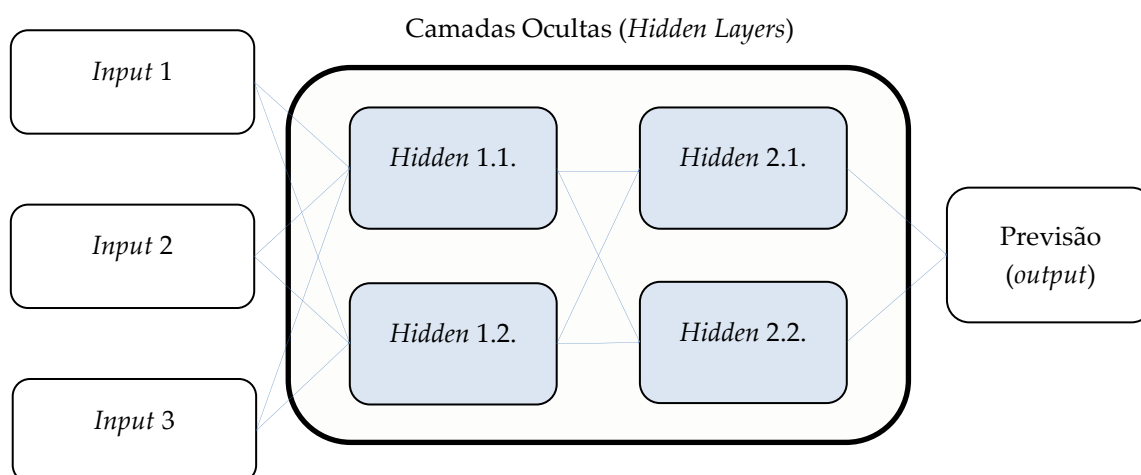
### 2.4.2.1 *Deep Neural Networks*

Como foi anteriormente mencionado, as redes neuronais têm a capacidade de “identificar” padrões que se formam através de relações de mercado imperceptíveis ao investidor (Rundo et al., 2019). A imperceptibilidade advém do facto de estas relações apresentarem um carácter não linear, dotado de uma combinação de fatores, entre os quais a sua influência ser pouco perceptível e difundida ao longo do tempo, no entanto determinadora. Assim, estes modelos têm de ser aplicados, tendo em conta um conjunto de regras para não serem identificadas relações baseadas na lei dos grandes números. Este fenómeno chama-se *overfitting*.

A estrutura e arquitetura das DNN foi inspirada no cérebro humano. Estas são compostas por uma camada de *inputs*, uma de *outputs* e apresentam pelo menos uma “camada escondida” (Tsay, 2005). Estas apresentam a capacidade de processar grandes conjuntos de dados, mapeando relações não lineares baseadas em dados históricos (de treino e validação) que lhes permitem obter previsões probabilísticas sobre eventos futuros. São conhecidas pela sua eficiência, adaptabilidade e versatilidade na aplicação.

O mapeamento da informação dá-se nas sinapses que na realidade funcionam como fatores de ponderação (Tsay, 2005). Ou seja, este método tem a capacidade de integrar várias variáveis, disponibilizadas ao modelo pela camada de *inputs*, numa só, convertendo os dados de entrada em dados mais complexos através das camadas ocultas. No processo de treino de uma DNN, os pesos associados a cada uma das sinapses vão-se alterar de forma a alcançarmos o menor erro do resultado face ao valor verificado (Tsay, 2005).

O número de neurónios presentes na 1ª camada da DNN corresponde ao número de variáveis que são utilizadas no modelo. O número de camadas ocultas e o número de neurónios em cada uma destas são dois dos parâmetros que são escolhidos por quem desenha o modelo e são subjetíveis de otimização (Tsay, 2005). A última camada é a de *output*, de onde resulta a previsão do modelo.



**Figura 1:** esquema de uma DNN

As DNN podem ser usadas tanto para classificação de dados como para regressões complexas (Moolayil, 2019). Este estudo irá utilizar um modelo de regressão onde a variável que pretendemos prever contém valores exatos. Apesar de estes modelos à partida não estarem preparados para receber séries temporais, neste estudo foi utilizado um método que confere ao modelo, de forma indireta (mantendo a estrutura de uma DNN e não de uma *Recurrent Neural Network*), captar o efeito da série temporal. Este método será explicado na Metodologia.

#### 2.4.2.1.1 Seleção dos *inputs* e pré-processamento

Um dos passos mais importantes na construção de um modelo é o pré-processamento no que diz respeito à seleção e tratamento das variáveis. Neste sentido, é importante ter uma perceção dos dados que têm maior informação sobre a variável que estamos a tentar prever, para que a DNN seja treinada da forma mais eficiente e evite problemas de *overfitting* (Moolayil, 2019). Há um conjunto de variáveis infinitas que podem ter influência no fator que pretendemos prever, no entanto, apenas um grupo delas pode integrar o modelo. Quanto maior o número, mais lento e menos robusto será o modelo. Por outro

lado, as variáveis escolhidas têm de conter informação suficiente. Este é um processo que requer sensibilidade adquirida (Moolayil, 2019).

Neste segmento, destaca-se a necessidade de “colocar à escala” as variáveis utilizadas para que seja mais fácil salientar tendências, minimizar o ruído, e diminuir o tempo de treino (Moolayil, 2019). Como vimos na secção anterior, quanto maior a magnitude do valor do *input*, maior o efeito deste sobre o fator de ponderação (peso). Caso a magnitude de um dos inputs seja muito superior aos outros, é necessário um maior número de *epochs* (iterações) durante o treino do modelo para que o fator de ponderação consiga captar o efeito dessa variável. Moolayil (2019) afirma que a solução para este problema é colocar todos os vetores de inputs à mesma escala ou normalizados. Muitos modelos exigem que os dados de entrada estejam normalizados ou escalonados, mas este não é o caso das DNN. No entanto, apesar de este tipo de modelo não requerer que as variáveis sejam normalizadas, já que o algoritmo tem a capacidade de adaptar os fatores de ponderação, este passo deve ser realizado, pois terá influência sobre a eficiência do modelo e o tempo que esta demora a ser treinado (Moolayil, 2019).

#### 2.4.2.1.2 Processo de treino das DNN

Cada neurónio da 1ª camada, que representa uma variável, recebe a informação histórica dessa variável. Por sua vez, cada um destes neurónios está conectado a todos os neurónios presentes na segunda camada (camada oculta) através de uma sinapse (Moolayil, 2019). A sinapse funciona com um processo de seleção das variáveis, dentro da NN, através de um sistema de ponderação. O sistema de ponderação funciona com base numa função de ativação à qual é fornecida um *input*, gerando um sinal, caso a condição seja satisfeita (Sako,

Mpinda & Rodrigues, 2022). Os tipos mais comuns de funções de ativação são os seguintes:

$$ReLU(k) = \max(0, k)$$

$$Sigmoid(k) = \frac{1}{1 + e^{-k}}$$

$$tanh(k) = \frac{e^k - e^{-k}}{e^k + e^{-k}}$$

$$Softmax_i(k) = \frac{e^{k_i}}{\sum_j e^{k_j}}$$

Caso a informação não seja relevante, a sinapse, através da atribuição de um peso de zero, impede que a informação passe, por outro lado, caso a informação em causa contribua de forma adversa para o resultado, o peso será negativo. Nesta segunda camada dá-se uma recombinação, por tentativa erro (*epochs*), dos vários tipos de dados de entrada em subgrupos.

Entre a primeira e a última camada encontram-se as camadas “intermédias” ou ocultas da rede neuronal, no entanto, o facto de só vermos os valores de entrada e o resultado, dá a sensação de que estes modelos são uma espécie de *black box*. Quanto mais complexas as relações presentes nestas camadas mais prolongado é o processo de treino e maior o risco de *overfitting* (Moolayil, 2019). É nesta perspetiva que se erguem os conceitos da aplicação prática como a robustez de uma NN. Este conceito resulta de um *trade-off* entre 3 fatores, o número de níveis de decisão, neurónios em cada nível, e *inputs*, e a possibilidade da solução encontrada ser muito generalizada ou demasiado específica. Quanto maior o número de níveis e de neurónios, maior o número de combinações aumentando assim a perceção a padrões de mercado bastante específicos, que provavelmente não se voltarão a repetir no futuro (Moolayil, 2019). A este fenómeno dá-se o nome de *overfitting*. Por outro lado, também existe a

possibilidade de a solução do modelo ser demasiado generalizada devido ao excesso de *inputs* e recombinações, o que resulta em margens de risco elevadas e de difícil implantação. O processo de treino de uma NN tem de ser gradual e faseado, caminhando de uma solução generalizada para uma mais específica.

Na última camada é gerado um *output* com base nos melhores parâmetros ( $W$ ,  $b$ ). Estes parâmetros são encontrados no processo de treino (aprendizagem) da rede neuronal, denominado por *back propagation* e definido por 3 fases (Sako, Mpinda & Rodrigues, 2022):

1. *Forward propagation approach* - ocorre ao nível de cada neurónio e é definida pela seguinte equação:

$$Y = \sigma(W * X + b)$$

- O  $Y$  é o *output*,  $X$  é o *input*,  $W$  é o peso e  $b$  é o enviesamento da camada;

2. *Loss function* – consiste na comparação entre o *output* estimado pela equação anterior com o valor observado, através de uma *cost function*. O *mean squared error* (MSE) é a métrica mais utilizada para problemas de regressão, e é definido pela seguinte equação:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - Y'_i)^2$$

- $n$ : número de entradas de *inputs*;
3. Otimização dos pesos e do enviesamento – nesta fase são utilizados algoritmos de otimização para atualizar os parâmetros da DNN como os pesos e o enviesamento. A otimização é feita em função da

minimização da *loss function*. O algoritmo de otimização mais utilizado é o do *gradient descent*.

#### 2.4.2.2 Tendências

Segundo Bartram, Branke e Motahari (2020) os modelos de IA têm vindo a ganhar, cada vez mais, um papel central no que diz respeito, não só à formulação das hipóteses, como também à tomada de decisão dos sistemas de transação. No entanto, ainda se trata de um tema emergente, tanto no mundo académico, como na sua aplicação ao mundo real. Neste sentido, analisando trabalhos de investigação, enquadrados na tipologia de revisão bibliográfica, torna-se evidente que este é um campo de investigação que se encontra com uma taxa de atualização e inovação bastante elevada (Hu, Zhao & Khushi, 2021; Li & Bastos, 2020; Rundo, Trenta, di Stallo & Battiato, 2019; Sezer, Gudelek & Ozbayoglu, 2020). Vários autores abordam os problemas relacionados com a análise de séries temporais a partir de modelos tradicionais, e daqui fazem uma comparação com os sistemas baseados em IA, salientando a capacidade de esses superarem a *performance* dos modelos lineares (Rundo et al., 2019). Nos artigos de revisão bibliográfica, é dado destaque à utilização de *Recurrent Neural Networks* (RNN) pelo facto de serem mais apropriadas à análise de séries temporais. Contudo, é possível existirem séries temporais com DNN e existem estudos que estabelecem a comparação entre os modelos lineares (ARIMA) e as DNN (Furnham & Boo, 2011; Lou, Wang, Gao & Zeng, 2022; Sako, Mpinda & Rodrigues, 2022; Shabri, Samsudin & Yusoff, 2020).

#### 2.4.3 Medidas de *performance*

Neste estudo a precisão dos modelos abordados será avaliada através de duas medidas diferentes o *Root Mean Square Error* (RSME), que resulta do *Mean Square Error* (MSE), e o *Mean Absolute Error* (MAE):

O MSE qualifica a precisão do modelo com base na diferença do erro médio da regressão ao quadrado. Quanto mais próximo de zero estiver o MSE, melhor o poder explicativo do modelo. Incorpora não só a variância como também o enviesamento do estimador.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - Y'_i)^2$$

O RSME qualifica a precisão do modelo com base na raiz quadrada da diferença do erro médio da regressão ao quadrado. Esta métrica agrega a magnitude dos erros das previsões do modelo, e serve de termo de comparação do erro previsional entre diferentes modelos ou *data sets*.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - Y'_i)^2} = \sqrt{MSE}$$

O MAE que mede a média dos erros absolutos, e é obtido pela seguinte fórmula:

$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n}$$

O MAE considera cada um dos erros que contribui para a métrica com o mesmo peso, o que não acontece no RSME que acaba por atribuir um maior peso aos maiores erros. Por este motivo, o MAE tem a capacidade de minimizar o efeito dos *outliers* nas previsões (Chai & Draxler, 2014).

## Capítulo 3 - Metodologia

### 3.1 Objetivos e enquadramento

Antes de dar início à metodologia é importante esclarecermos alguns conceitos que irão clarificar a perspetiva com que foi realizada esta investigação.

Um sistema de transação (*robo-trader*) é um programa que permite ao investidor tomar decisões a partir de regras matemáticas adaptado às suas preferências. As vantagens destes sistemas de transação passam pela ausência de ambiguidade e emoção no momento da tomada de decisão, conferindo aos agentes de mercado uma mecânica de investimento sistemática. O desenvolvimento de um sistema de transação parte da formulação de uma hipótese. É nesta fase que se dá a seleção de variáveis que conferem uma vantagem competitiva no mercado. No entanto, a rentabilidade de uma estratégia está dependente de outros parâmetros para além da hipótese testada. A seleção de um *timeframe*, regras de entrada e saída do mercado e as estratégias de gestão de risco e banca, são dos aspetos mais importantes.

Tendo em conta a contextualização teórica do mercado em estudo, este trabalho de investigação não passa pela formulação de um sistema de transação, mas sim pela formulação de uma hipótese que apresenta uma forte relação com

a teoria económica e financeira, que poderá, mais tarde, vir a ser capitalizada através de uma estratégia de transação.

Neste estudo, partimos da base teórica de que os mercados financeiros apresentam uma natureza caótica e determinística (teoria do caos), onde a estrutura de mercado apresenta relações não lineares. Ao mesmo tempo, este estudo procura a evidência de um sincronismo comportamental no curto prazo (finanças comportamentais).

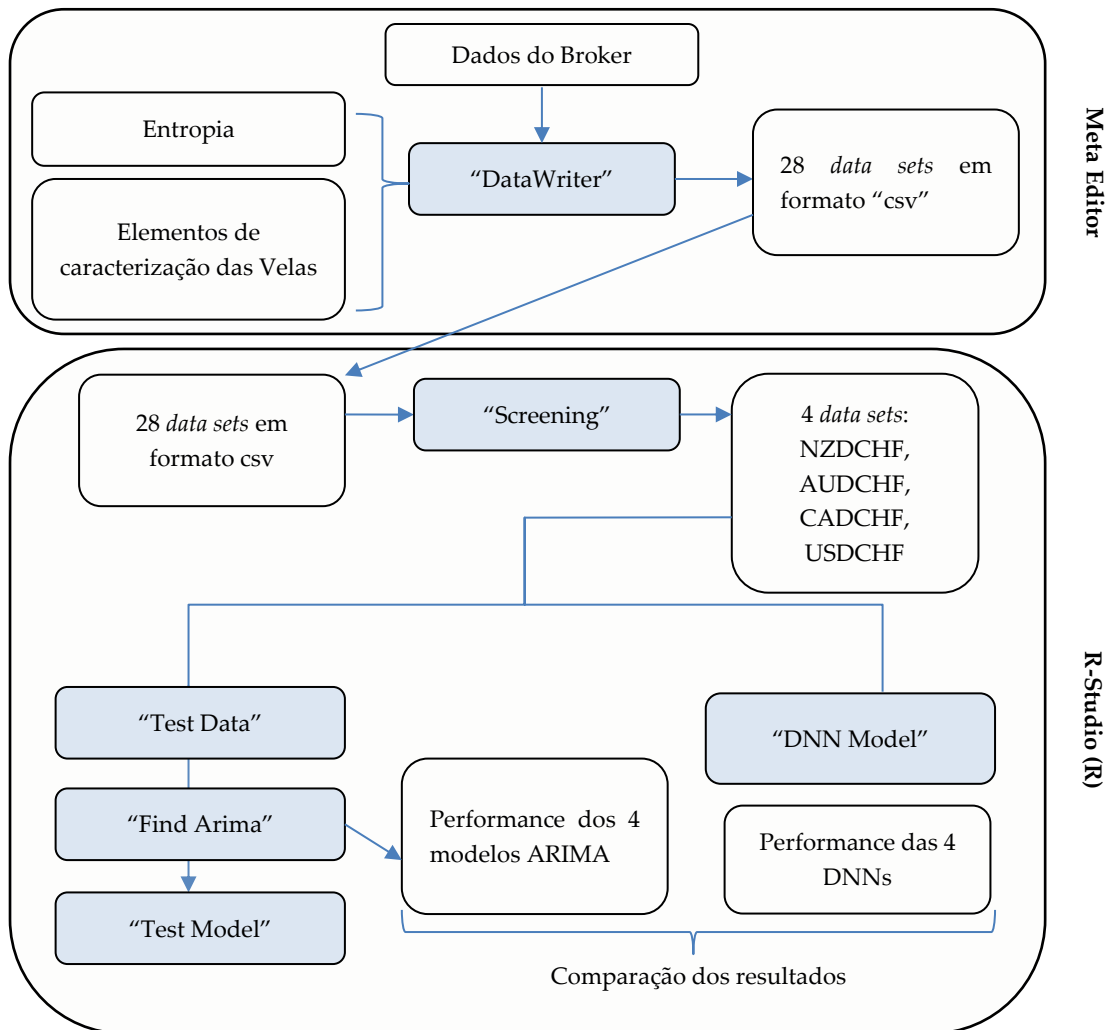
O objetivo desta metodologia passa pela comparação entre modelos lineares associados às finanças tradicionais e os modelos não lineares que procuram modelar o comportamento humano, na tentativa de ultrapassar obstáculos como o ruído de mercado gerado pelo caos, sendo este impossível de medir. A hipótese testada neste trabalho recai sobre a capacidade de previsão de padrões comportamentais do mercado cambial, comparando modelos de regressão linear e não linear, relativamente a um cesto de pares cambiais agrupados pelo nível de volatilidade.

É importante salientar que a integração destes modelos de IA (não lineares) em sistemas de transação não têm necessariamente como principal objetivo prever o preço futuro de um ativo, podendo enveredar por outros caminhos como a previsão do retorno do ativo para um dado período. Neste sentido, também é de referir que nem sempre os modelos com uma menor métrica de erro médio apresentam as estratégias mais lucrativas.

### 3.1.1 Enquadramento da investigação

#### 3.1.1.1. Ambiente da investigação

Para a extração de dados foi usado o MT5 (versão 5.00), um software de transação da MetaQuotes com a sua linguagem de programação, o MQL5 (com base no C++). Nesta plataforma foi criado um algoritmo com o nome “DataWriter” e um indicador “Entropia” que foram escritos de raiz com base no descrito na revisão de literatura.



**Figura 2:** fluxograma da metodologia

Nesta investigação é também usada uma segunda linguagem de programação, o R com o IDE Rstudio e as *libraries* “tidyverse”, “h2o”, “lubridate” e “magrittr”. Neste *software* foram criados vários algoritmos. Na figura 2 foi esquematizada a estrutura e organização dos *scripts* criados, com a descrição das suas funcionalidades.

### 3.1.1.2. Descrição dos dados

Neste estudo foram analisadas séries temporais dos 28 pares cambiais, baseados nas 8 principais moedas mencionadas na revisão de literatura (RL). Os dados sob análise cobrem um horizonte temporal de 16/05/2012 a 15/03/2023 com uma frequência semi-diária (12h), totalizando assim 5001 observações.

Este conjunto de inputs terá em conta um *shift* de 6 velas (de  $t$  a  $t-5$ ), ou seja, cada linha da tabela de inputs irá conter 6 momentos, cada um representado por uma vela de 12h. Assim, o conjunto de dados irá contemplar um conjunto de 43 colunas (variáveis): uma variável dependente e 42 independentes (6 períodos, cada um caracterizado por 7 elementos).

A variável que pretendemos prever é o Retorno em  $t+1$ . Para isto foram usados 6 elementos para caracterizar cada vela (o tipo de vela, o pavio superior %, o pavio inferior %, o corpo da vela % e o tamanho da vela atual face à anterior), uma variável para integrar o *gap* entre o *close price* de uma vela e o *open price* da seguinte e, por fim, uma variável para caracterizar a incerteza do mercado, a entropia. A seleção das variáveis deste estudo foi feita com uma base fundamental, sendo assim suportada pela revisão de literatura. Posto isto, o conjunto de dados de entrada engloba as seguintes variáveis para cada um dos pares cambiais:

1. retorno: alteração percentual da vela

- $(\text{Close}_{t+1} - \text{Open}_{t+1}) / \text{Open}_{t+1}$

2. tipo de vela: classificação da vela em ascendente, descendente ou neutra;
  - $Open_t < Close_t = 1$ ;
  - $Open_t > Close_t = -1$ ;
  - $Open_t = Close_t = 0$ ;
  
3. pavio superior (%): representação percentual do pavio superior;
  - Se a vela for ascendente:  $(High_t - Close_t) / (High_t - Low_t)$ ;
  - Se a vela for descendente:  $(High_t - Open_t) / (High_t - Low_t)$ ;
  
4. pavio inferior (%): representação percentual do pavio inferior;
  - Se a vela for ascendente:  $(Open_t - Low_t) / (High_t - Low_t)$ ;
  - Se a vela for descendente:  $(Close_t - Low_t) / (High_t - Low_t)$ ;
  
5. corpo da vela (%): representação percentual do corpo no tamanho total da vela;
  - $(|Open_t - Close_t|) / (High_t - Low_t)$ ;
  
6. tamanho da vela (rácio): tamanho da vela atual face à anterior;
  - $(High_t - Low_t) / (High_{t-1} - Low_{t-1})$ ;
  
7. gap: diferença entre o *open* da vela atual e o *close* da vela anterior;
  - $(Open_t - Close_{t-1}) / Close_{t-1}$
  
8. entropia: indicador estudado na RL
  - $(Entropia_t - Entropia_{t-1}) / Entropia_{t-1}$

### 3.1.1.3 Recolha de dados

A recolha dos dados foi feita a partir de um algoritmo criado no MetaEditor (o IDE do MQL5), e os dados em si são provenientes do broker “Admiral Markets”. O MT5 é a ponte de ligação ao broker. O algoritmo, “DataWriter”, foi desenhado com este único propósito de extrair os dados no formato descrito na secção anterior. Este armazena e estrutura os dados em ficheiros “csv”, que irão ser posteriormente analisados noutra ambiente.

### 3.1.1.4. Pré-processamento

O pré-processamento dos dados foi efetuado através de um script com o nome “Screening” escrito em R, no R-Studio. Sem aparentar, este passo é dos mais importantes no que toca ao poder provisional da metodologia. É de salientar que o poder de previsão não reside somente no modelo utilizado, mas também noutros fatores como a qualidade dos dados que constituem o *data set*. Sendo assim, existem três secções importantes na gestão dos dados em estudo: a limpeza, a seleção, transformação e a separação dos dados.

#### 3.1.1.4.1. Limpeza dos dados

O processo de limpeza dos dados é essencial, pois o *data set* pode conter observações em falta ou erradas. Neste sentido, foram executados dois conjuntos diferentes de procedimentos: a identificação de valores em falta e a identificação de observações erradas. Com o *script* é possível concluir que o conjunto de dados extraído não apresentava dados em falta. A identificação e correção de *outliers* foi feita após a seleção dos pares cambiais para o estudo.

Contudo, para a identificação e correção de *outliers* é necessário ter em atenção a natureza dos dados. O método de normalização min-max não pode ser utilizado para todas as variáveis. Este método de pré-processamento de dados

parte do princípio de que as variáveis em estudo têm um valor mínimo e máximo registados nas observações da amostra. No entanto, isto não se verifica em todas as variáveis do modelo, já que o valor mínimo e o valor máximo podem tender para infinito. Assim teremos de optar pelo processo de normalização z-score dos dados. O processo de normalização z-score envolve a transformação da variável numa série com uma distribuição próxima à distribuição normal, diminuído a magnitude do valor da variável e mantendo o comportamento que se pretende capturar.

Para realizar este procedimento foi utilizada função “*hampel()*” da *library* “*pracma*” que implementa o *Hampel filter* (Pearson, 1999), que é utilizado para detetar e corrigir *outliers*. Um dos parâmetros desta função é o valor z-score. O z-score selecionado foi 2,6 (nível de confiança bilateral de 1%) para a correção da amostra. Desta forma, os valores que se encontravam fora de 99% da amostra, à esquerda e à direita da distribuição, foram substituídos por valores próximos da média. Este filtro tem a vantagem de poder ser aplicado a amostras que não sigam uma distribuição normal.

#### 3.1.1.4.2. Seleção dos pares cambiais

No processo de seleção dos dados, dos 28 pares cambiais foi selecionado um grupo de 4 pares: o *top 4*. O *top 4* é o cesto com os 4 pares cambiais mais voláteis com base no desvio padrão. Com esta seleção pretende-se abordar os pares cambiais que apresentam movimentos de maior amplitude ao longo do tempo, sendo a modelação destes mais relevante do que a modelação de pares cambiais que têm poucas oscilações. Desta forma, os pares cambiais que serão testados encontram-se apresentados na seguinte tabela:

R output: seleção dos pares cambiais

<i>top 4</i>	desvio padrão
NZDCHF	0,008039829
AUDCHF	0,007677536
CADCHF	0,005827759
USDCHF	0,005549412

**Tabela 2:** seleção dos pares cambiais

É de notar que o CHF está presente em todos os pares cambiais da seleção. Isto pode ser explicado pelo abandono da paridade face ao euro em 2015 e pelo facto de em eventos de stress de mercado o franco suíço ser um ativo de reserva.

#### 3.1.1.4.3. Transformação dos dados

Assim como foi abordado na revisão de literatura, o processo de normalização utilizado nesta metodologia foi o z-score. Foi feita uma transformação das variáveis *gap* e entropia, aproximando a distribuição das séries à distribuição normal. Para realizar a transformação das séries foi utilizada a função `scale()` da *library* “base” do R. A função foi aplicada nas colunas dos *data sets* (de cada par cambial) referentes à variável *gap* e entropia, de  $t-1$  a  $t-6$ . O tempo de treino da DNN diminuiu em média de 4 min para 30 segundos. Não se procedeu à normalização das restantes variáveis já que estas têm uma dimensão (magnitude) apropriada.

#### 3.1.1.4.4. Separação dos dados em sets de treino e teste

Na forma mais comum de separação da base de dados, dá-se a divisão da mesma em dois subconjuntos, treino e teste. O primeiro passo consiste no treino do modelo com base nos dados históricos iniciais (*in-sample*) e numa segunda fase dá-se o teste do modelo sobre os dados restantes (*out-of-sample*). Neste

estudo, o conjunto de dados teste tem uma representatividade de 70%, enquanto os restantes 30% dizem respeito aos dados de teste. Esta é a separação mais utilizada (Öztürk, 2015). Contudo, é importante referir que a separação dos dados foi feita respeitando a cronologia das observações (70% mais antigas para treino e as 30% mais recentes para teste), pelo facto de estarmos a trabalhar com séries temporais não pode ser feita uma seleção aleatória (em 70% e 30%) dos dados.

### 3.1.2. Modelação linear

#### 3.1.2.1 Testes à estacionariedade

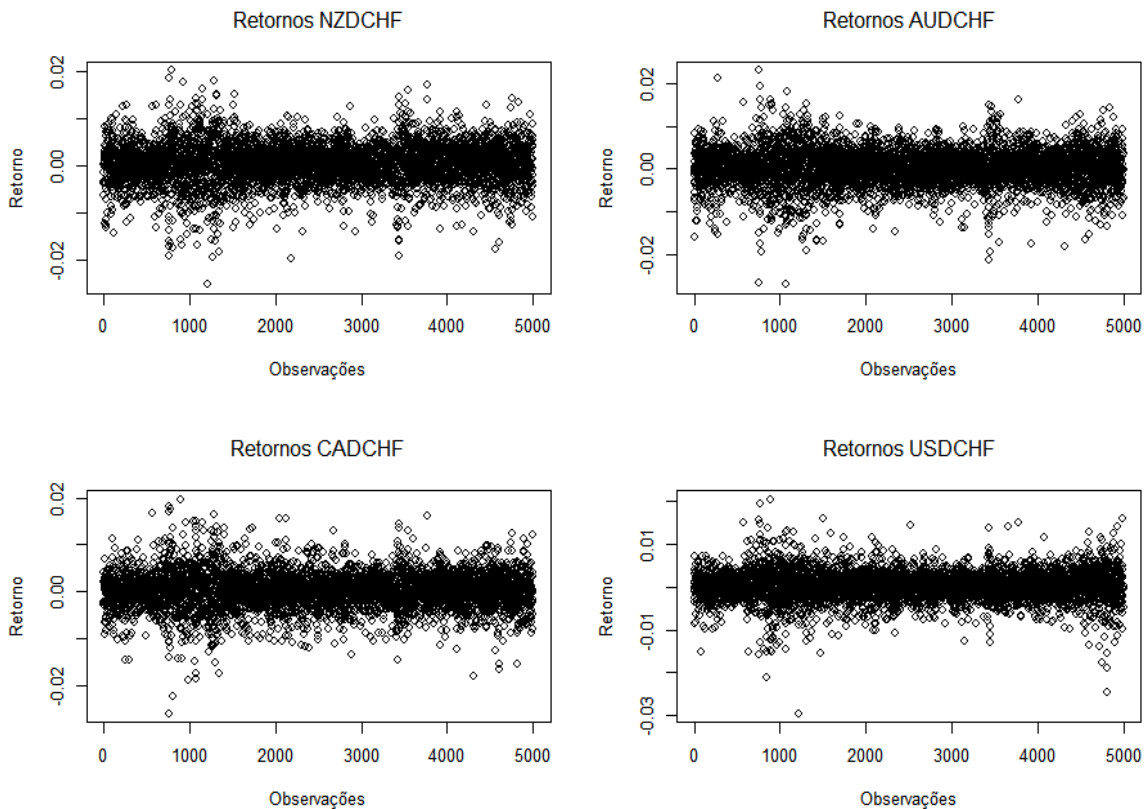
Antes de proceder à modelação ARIMA, foi escrito um *script* (“Test Data”) para testar a estacionariedade da série temporal, com o objetivo de verificar se as observações registadas não apresentam uma tendência ou sazonalidade ao longo do tempo. Como a modelação ARIMA incide apenas sobre uma variável, o teste vai ser realizado em relação aos retornos de cada um dos pares cambiais sob estudo, sendo que esta é a variável que estamos a tentar prever.

*R output: Augmented Dickey-Fuller Test*

Retornos	NZDCHF	AUDCHF	CADCHF	USDCHF
Dickey-Fuller	-16,87	-17,461	-17,247	-17,609
Lag order	17	17	17	17
<i>p-value</i> <sup>2</sup>	0,01*	0,01*	0,01*	0,01*

**Tabela 3:** *R output - Augmented Dickey-Fuller Test*

<sup>2</sup> “\*” – o valor é inferior ao apresentado.



**Figura 3:** *scatter plot* dos retornos dos pares cambiais selecionados

A estacionariedade das séries temporais foi verificada através dos gráficos apresentados, que não espelham um padrão ou tendência aparente e também com o teste do Augmented Dickey-Fuller (Dickey & Fuller, 1981), efetuado com a função “`adf.test()`” da *library* “`tseries`”. Como podemos observar, em todos os testes realizados o *p-value* registado foi inferior a 1%. Com isto é possível rejeitar a hipótese nula e assumir que as séries sob estudo são estacionárias. O *lag order* de 17 foi calculado a partir da seguinte fórmula:  $n-1^{1/3}$ , onde  $n$  é o número de observações (Schwert, 1989). Esta fórmula tem por base a ideia de que à medida que o tamanho da amostra aumenta, aumenta também o *lag* necessário para tornar a série estacionária, e assim a fórmula usa o tamanho da amostra para calcular o número ótimo aproximado de *lags*.

### 3.1.2.2. Modelo ARIMA

Após ter sido testada a estacionariedade da série temporal o próximo passo é encontrar quais os melhores parâmetros AR e MA para corrigir a autocorrelação presente na série temporal. Os correlogramas de autocorrelação (ACF) e de autocorrelação parcial (PACF) serão utilizados para identificar, respectivamente, os melhores parâmetros de AR e MA. Contudo, pela falta de significância dos coeficientes do ACF e do PACF, o melhor modelo será selecionado com o critério de *Akaike Information Criterion* (AIC) e *Bayesian Information Criterion* (BIC). A seleção do melhor modelo através do AIC e do BIC é feita por análise de uma matriz, para cada critério, que contém vários modelos para as diversas ordens de AR(p) e MA(q) mantendo o termo de diferença contante e igual a zero, já que constatamos que a série é estacionária. Os modelos que apresentarem o menor AIC e o menor BIC são os melhores modelos. As fórmulas do AIC e do BIC são:

$$\text{AIC} = -2 \log(L) + 2 (p + d + q)$$

$$\text{BIC} = -2 \log(L) + \log(n) (p + d + q)$$

- L: *log-likelihood*;
- n: número de observações;
- p: termo AR;
- d: termo da diferença;
- q: termo MA.

A seleção do melhor modelo foi feita com o *script* “Find ARIMA” através da função “*auto.arima()*” da *library* “*forecast*”, que analisa todos os modelos possíveis para a série temporal com base na minimização do critério AIC e BIC. Foram identificados os seguintes modelos:

R output: "auto.arima()"

Retornos	ARIMA	Coeficientes	Cr�terios
NZDCHF	(1,1,0)	ar1: -0.5038	AIC = -27469,42
		Desv. P.: 0.0146	BIC = -27457,1
AUDCHF	(0,0,0)	M�dia: 2e-04	AIC=-28743,44
		Desv. P.: 1e-04	BIC=-28731,11
CADCHF	(0,0,0)	M�dia: 2e-04	AIC=-29689,06
		Desv. P.: 1e-04	BIC=-29676,74
USDCHF	(0,0,0)	M�dia: 2e-04	AIC=-30251,24
		Desv. P.: 1e-04	BIC=-30238,92

**Tabela 4:** R output - "auto.arima()"

Relativamente ao NZDCHF o melhor modelo encontrado foi o ARIMA (1,1,0). Este modelo inclui um termo autoregressivo (AR1) com o coeficiente igual a -0,5038 e um desvio padr o de 0,0146. No que toca aos restantes modelos obtidos podemos concluir que para o AUDCHF, para o CADCHF e para o USDCHF o melhor modelo encontrado foi, nos tr s casos, o ARIMA (0,0,0) com uma m dia de  $2 \times 10^{-4}$  e um desvio padr o de  $1 \times 10^{-4}$ . Este modelo   o *random walk*. Por fim, foram testados os seguintes pressupostos para cada um dos modelos:

*R output*: testes aos pressupostos

Resíduos dos modelos	Lilliefors		
	Box-Pierce test (Independência)	(Kolmogorov-Smirnov) (Normalidade)	Goldfeld-Quandt test (Homocedasticidade)
NZDCHF	X-squared = 81,356 <i>p-value</i> < 2,2e-16	D = 0,023336 <i>p-value</i> = 0,0001566	GQ = 1,3851 <i>p-value</i> = 5,303e-12
AUDCHF	X-squared = 0,088958 <i>p-value</i> = 0,7655	D = 0,035306 <i>p-value</i> = 8,517e-11	GQ = 1,1215 <i>p-value</i> = 0,008265
CADCHF	X-squared = 1,3933 <i>p-value</i> = 0,2379	D = 0,043799 <i>p-value</i> < 2,2e-16	GQ = 1,3819 <i>p-value</i> = 7,419e-12
USDCHF	X-squared = 0,84612 <i>p-value</i> = 0,3577	D = 0,045874 <i>p-value</i> < 2,2e-16	GQ = 1,4154 <i>p-value</i> = 2,122e-13

**Tabela 5:** *R output* - testes aos pressupostos

No que toca ao teste da independência, relativamente aos resíduos do modelo NZDCHF podemos afirmar que estes não cumprem o pressuposto da independência (*p-value* = 2,2e-16 < 0,05), mas os restantes cumprem. No teste da normalidade, os resíduos de todos os modelos não seguem uma distribuição normal (*p-value* < 0,05). Quanto ao teste da homocedasticidade como *p-value* < 0,05 para os resíduos de todos os modelos, podemos afirmar que os resíduos não apresentam uma variância homogénea. Como nenhum dos modelos preencheu todos os pressupostos, podemos afirmar que nenhum dos modelos é ajustado aos dados, contudo, estes modelos serão utilizados para termos comparativos (Escudero et al., 2021).

### 3.1.3. Modelação não linear (DNN)

As DNN não estão preparadas para modelar séries temporais, contudo, neste estudo foi utilizado um conjunto de variáveis que diferem no tempo (com 6

momentos) para conferir à previsão gerada pelo modelo uma noção de série temporal.

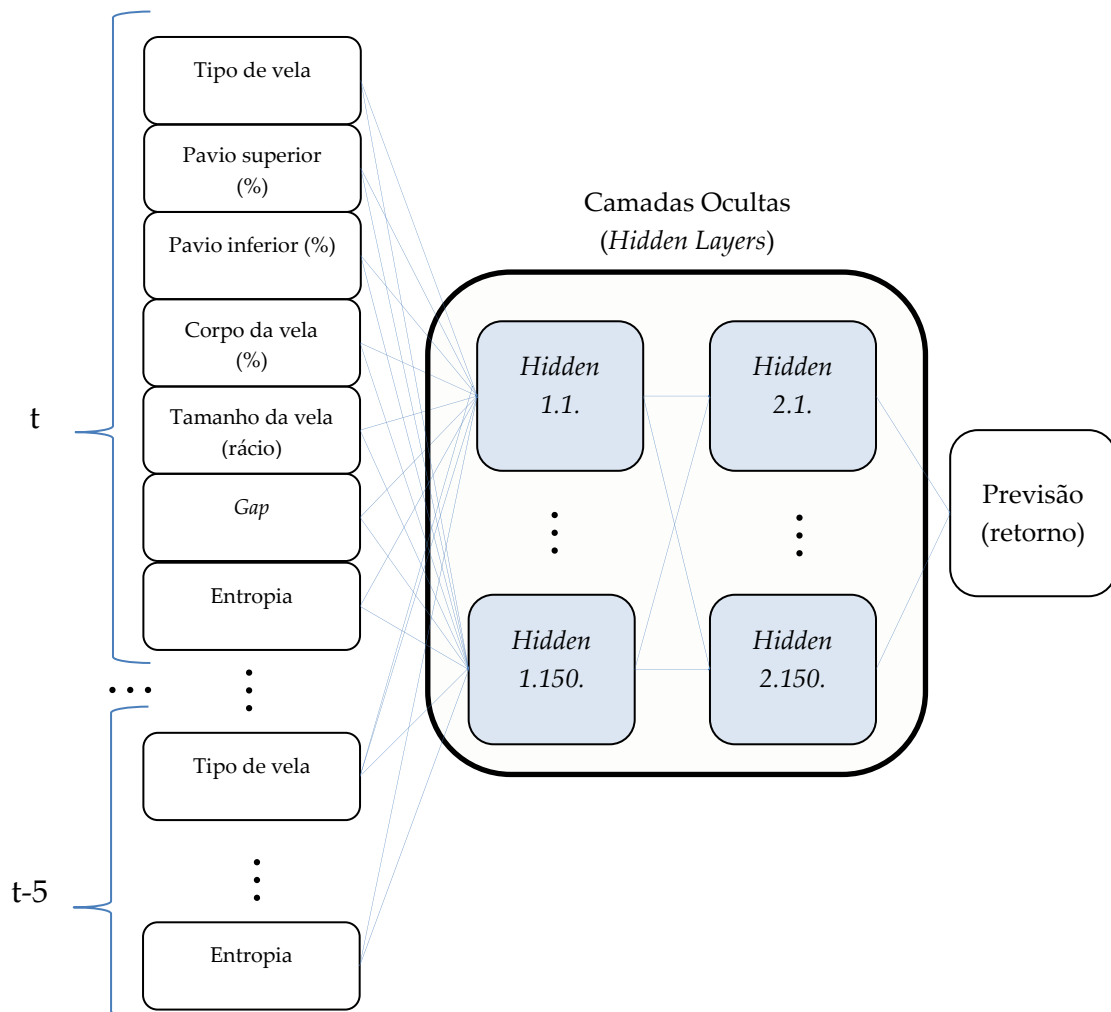
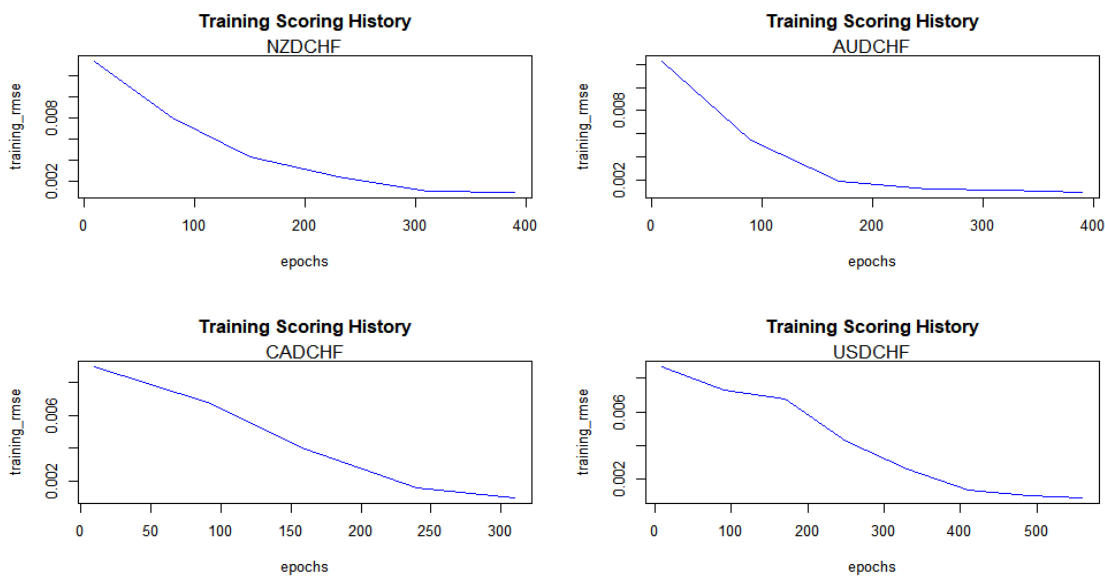


Figura 4: estrutura da DNN utilizada

As redes neurais para cada um dos pares cambiais foram criadas com a função "h2o.deeplearning()" da *library* "h2o". A rede neuronal considerada neste estudo como vetor de *input* por 42 neurónios que correspondem às variáveis dependentes descritas anteriormente. O vetor de *output* da rede neuronal é composto apenas por um neurónio que contém o valor da variável que pretendemos prever, neste caso o retorno estimado. Na arquitetura da rede neuronal foram considerados os seguintes parâmetros: duas *hidden layers* cada uma composta por 150 neurónios, a função de ativação selecionada foi a tangente (*Tanh*). O parâmetro *loss function* foi definido como "Automatic", para que seja escolhida a função mais apropriada tendo em conta os dados e o modelo. No mesmo sentido, o parâmetro *distribution* foi definido como "AUTO", para que a função escolha a distribuição mais apropriada da variável independente. Como última nota, a métrica usada para terminar o treino antecipadamente foi o "RMSE".



**Figura 5:** *scoring history* das DNNs criadas

## 3.2 Resultados

A previsão futura de séries temporais é considerada uma tarefa hercúlea. A distribuição dos retornos é constituída por uma grande quantidade de observações próximas da média histórica e uma quantidade mínima de retornos fortes, estando assim subentendido a *random walk*, onde a média é uma boa previsão em termo de erro médio (Fernandes, 2002). Assim, torna-se evidente a dificuldade de bater a *random walk* pela minimização dos erros, contudo, a forma de o fazer reside na previsão dos *outliers*, através da modelação não linear.

Nesta secção são comparadas as medidas de *performance* obtidas em cada um dos modelos, lineares e não lineares, para cada um dos pares cambiais selecionados.

R *output*: resultados dos modelos

<i>top 4</i>		NZDCHF	AUDCHF	CADCHF	USDCHF
<i>desvio padrão</i>		0,0080	0,0076	0,0058	0,0055
DNN	MSE	8,03E-07	7,19E-07	8,66E-07	7,49E-07
	RMSE	0,000896	0,000848	0,000931	0,000865
	MAE	0,000692	0,000664	0,000689	0,000703
<u>Modelo</u>		<u>(1,1,0)</u>	<u>(0,0,0)</u>	<u>(0,0,0)</u>	<u>(0,0,0)</u>
ARIMA	MSE	2,29E-05	1,59E-05	1,22E-05	1,04E-05
	RMSE	0,004783	0,003992	0,003488	0,003219
	MAE	0,003677	0,003018	0,002601	0,002358

**Tabela 6:** R *output* - resultados dos modelos

Olhando para a tabela podemos concluir que os erros obtidos através dos modelos DNN apresentam erros bem menos significativos do que aqueles

obtidos pelos modelos ARIMA de cada par cambial. Desta forma os resultados obtidos corroboram a ideia de que a modelação não linear tem um maior poder de previsão quando comparada aos modelos lineares. Para além disto, podemos observar que os *rankings* dos modelos estabelecidos pelo RSME e pelo MAE não são concordantes nas DNN, o que comprova que as previsões geradas pelas DNN conseguiram captar certos padrões de *outliers*, ao contrário dos modelos ARIMA que onde os *rankings* são concordantes. Entre os pares mais voláteis selecionados, os modelos ARIMA dos pares menos voláteis atingiram melhor desempenho e os mais voláteis pior desempenho, isto entra em concordância com o que foi mencionado no início desta secção.

## Capítulo 4 - Conclusão

Encontramos no mercado uma confluência de fatores que contribuem para uma repercussão de efeitos não lineares e não estacionários que fazem do processo previsional uma tarefa difícil. Assim como mencionado por muitos outros autores ao longo da história, podemos caracterizar os mercados como um processo aleatório. No entanto, as evidências de um comportamento estocástico não são plenas. Assim, estabelecemos a possibilidade de o mercado se comportar como um sistema determinístico não linear e não estocástico (caótico). Os mercados podem ser eficientes mesmo que por vezes surjam erros na avaliação dos ativos (Malkiel, 2003). Torna-se evidente a importância do horizonte temporal para o conceito da eficiência de mercado. No sentido em que, no curto prazo o mercado aproxima-se de um sistema de votos, enquanto no longo prazo é um mecanismo de ponderação, que acaba por revelar o verdadeiro valor dos ativos.

Esta investigação foi impulsionada pelo paradigma da teoria financeira explorada na revisão de literatura e está refletida no título deste trabalho de investigação. O título deste estudo, que aparenta ser uma contradição, é, na realidade, uma relação simbiótica entre a teoria das finanças comportamentais e a teoria do caos.

Por conseguinte, a questão de investigação formulada incide sobre a eficiência comparativa de modelos lineares e não lineares na previsão de retornos futuros. Os resultados empíricos deste estudo revelam que a performance dos modelos

de DNN é superior à performance dos modelos ARIMA, demonstrando assim que a modelação de relações não lineares, associada às teorias não convencionais, consegue descrever e obter melhores estimativas dos retornos futuros dos pares cambiais do que os modelos lineares associados às teorias convencionais da eficiência de mercado. Desta forma, foi alcançada uma concordância entre a revisão de literatura e os resultados obtidos.

Os principais contributos deste estudo passam pela adaptação da modelação das DNN a séries temporais, através segmentação dos *inputs* por *shifts* e pela conciliação das ferramentas de análise técnica utilizadas com DNN. O interesse prático deste estudo passa pela transformação da hipótese testada numa estratégia de transação rentável.

Podemos identificar as seguintes limitações ao estudo:

1. Nenhum dos modelos ARIMA obtidos preenche todos os pressupostos testados (independência dos erros, normalidade e homocedasticidade);
2. Relativamente à DNN podemos encontrar 2 grupos de limitações:
  - a. Foi assumido um *shift* de 6 velas para conferir ao modelo uma noção de série temporal, contudo este parâmetro pode ser otimizado para alcançar um nível superior de eficiência no modelo;
  - b. Os parâmetros, a estrutura da DNN (número de *hidden layers* e neurónios) e a função de ativação foram assumidos e não decorrentes de um processo de otimização;
3. Contudo, é importante referir que a otimização excessiva destes parâmetros pode levar ao *overfitting*;

Com o objetivo de dar uma continuidade a este trabalho de investigação, será interessante explorar:

1. Otimização dos diferentes parâmetros e estrutura da rede neuronal;
2. Adoção de um modelo híbrido (ARIMA-DNN) ou um ARIMA não linear (NAR) (Alrweili & Fawzy, 2022);
3. Adoção de modelos ARIMA que captam outros efeitos (Shabri et al., 2020);
4. Associar a hipótese testada a uma estratégia e avaliar os resultados com outras métricas de performance, como por exemplo a rentabilidade;
5. Introdução de variáveis de base fundamental;
  - a. Exemplo: associar a cada vela uma variável compreendida entre 0 e 3, relativa à importância dos eventos de mercado programados.

Quando aplicamos redes neurais em sistemas fechados (nos quais os resultados são finitos e o conjunto de dados consegue descrevê-los de forma completa), estas acabam, geralmente, por encontrar uma solução correta. No entanto, os mercados financeiros não são um sistema fechado, comprovando-se pela oscilação do nível de incerteza (conceito de entropia). A aplicação das DNN nos mercados financeiros difere da sua aplicação noutras áreas (como a física e a química) nas quais costuma existir uma solução para um problema. Como nos mercados financeiros não existe uma solução evidente, os resultados destes modelos terão de ser otimizados e testados para comprovar a sua qualidade de previsão ou classificação. Assim, a aplicação dos modelos de inteligência artificial aos mercados financeiros conhece o limiar da sua aplicabilidade na natureza semiplena das interações e implicações de mercado (onde a formação de preços é caótica e proveniente da psicologia cognitiva e dos limites da arbitragem), que ao mesmo tempo se estabelece como a base do sucesso para atingir uma solução admissível em função de um objetivo (a não necessidade de encontrar uma solução ótima).

# Bibliografia

- Alrweili, H. & Fawzy, H. 2022. Forecasting Crude Oil Prices Using an ARIMA-ANN Hybrid Model. *Journal of Statistics Applications & Probability An International Journal*, 11(3): 845-855.
- Archer, M. D. & Bickford, J. 2008. *Getting Started in Currency. Trading Winning in Today'S Hottest Marketplace*. New Jersey: John Wiley & Sons, Inc.
- Bachelier, L. 1900. The Theory of Speculation. *Annales Scientifiques de l'École Normale Supérieure*, 3(17): 21–86.
- Barberis, N. & Thaler, R. 2003. *A survey of behavioral finance*. Working paper No. 9222, National Bureau of Economic Research, Cambridge, MA.
- Bartram, S. M., Branke, J. & Motahari, M. 2020. *Artificial Intelligence in Asset Management*. Charlottesville, VA: CFA Institute Research Foundation.
- Bentes, S. R. & Menezes, R. 2012. Entropy: A new measure of stock market volatility? *Journal of Physics: Conference Series*, 394(1): 012033.
- Bloomfield, R. & Hales, J. 2002. Predicting the next step of a random walk: experimental evidence of regime-shifting beliefs. *Journal of Financial Economics*, 65(3): 397–414.
- Box, G. 2013. Box and Jenkins: Time Series Analysis, Forecasting and Control. In T. C. Mills (Ed.), *A Very British Affair*: 161–215. London: Plagrave Macmillan.
- Chai, T. & Draxler, R. R. 2014. Root mean square error (RMSE) or mean absolute error (MAE)?-Arguments against avoiding RMSE in the literature. *Geosci. Model Dev*, 7(3): 1247–1250.
- Chen, P. 1988. Empirical and theoretical evidence of economic chaos. *System Dynamics Review*, 4(1–2): 81–108.

- Corsetti, G., Lafarguette, R. & Mehl, A. 2019. *Fast Trading and the Virtue of Entropy: Evidence from the Foreign Exchange Market*. Working Paper No. 2300, European Central Bank, Frankfurt.
- Davis, J., Hands, D. & Mäki, U. 1998. Chaos in Economics. In Eduard Elgar Publishing (Ed.), *The Handbook of Economic Methodology*: 59-63. Cheltenham, UK: In Eduard Elgar Publishing.
- Delcey, T. 2019. Samuelson vs Fama on the efficient market hypothesis: The point of view of expertise. *OEconomia*, 9(1): 37–58.
- Dickey, D. A. & Fuller, W. A. 1981. Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root. *Econometrica*, 49(4): 1057.
- Dionisio, A., Menezes, R. & Mendes, D. A. 2006. An econophysics approach to analyse uncertainty in financial markets: an application to the Portuguese stock market. *The European Physical Journal B - Condensed Matter and Complex Systems*, 50(1): 161–164.
- Dupernex, S. 2007. Why might share prices follow a random walk. *Student Economic Review*, 21: 167-179.
- Escudero, P., Alcocer, W., Paredes, J., Gimeno-Blanes, J., Soguero-Ruiz, C., et al. 2021. Recurrent Neural Networks and ARIMA Models for Euro/Dollar Exchange Rate Forecasting. *Applied Sciences* 2021, 11(12): 5658.
- Faggini, M. & Parziale, A. 2012a. The Failure of Economic Theory. Lessons from Chaos Theory. *Modern Economy*, 3(1): 1–10.
- Fama, E. F. 1965a. The Behavior of Stock-Market Prices. *The Journal of Business*, 38(1): 34–105.
- Fama, E. F. 1965b. Random Walks in Stock Market Prices. *Financial Analysts Journal*, 21(5): 55–59.

- Fama, E. F. 1970. Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, 25(2): 383-417.
- Fama, E. F. 1976. Efficient Capital Markets: Reply. *The Journal of Finance*, 31(1): 143-145.
- Federici, D. & Gandolfo, G. 2014. Chaos in Economics 1. *Journal of Economics and Development Studies*, 2(1): 51-79.
- Fernandes, M. C. 2002. Técnicas de Inteligência Artificial Aplicadas à Previsão de Series Temporais Financeiras. *Dissertação de Mestrado*. Porto: Faculdade de Economia da Universidade do Porto.
- Furnham, A. & Boo, H. C. 2011. A literature review of the anchoring effect. *The Journal of Socio-Economics*, 40(1): 35-42.
- Genesove, D. & Mayer, C. 2001. Loss Aversion and Seller Behavior: Evidence from the Housing Market. *The Quarterly Journal of Economics*, 116(4): 1233-1260.
- Hong, H., Lim, T. & Stein, J. C. 2000. Bad News Travels Slowly: Size, Analyst Coverage, and the Profitability of Momentum Strategies. *The Journal of Finance*, 55(1): 265-295.
- Hsieh, D. A. 1991. Chaos and Nonlinear Dynamics: Application to Financial Markets. *The Journal of Finance*, 46(5): 1839-1877.
- Hu, Z., Zhao, Y. & Khushi, M. 2021, March 1. A survey of forex and stock price prediction using deep learning. *Applied System Innovation*. 4(1): 9.
- Kahneman, D. & Tversky, A. 1979. Prospect Theory: An Analysis of Decision under Risk. *Econometrica*, 47(2): 263-292.
- Klioutchnikov, I., Sigova, M. & Beizerov, N. 2017. Chaos Theory in Finance. *Procedia Computer Science*, 119: 368-375.

- Kumar, S. & Goyal, N. 2016. Evidence on rationality and behavioural biases in investment decision making. *Qualitative Research in Financial Markets*, 8(4): 270–287.
- Lee, C. M. C., Shleifer, A. & Thaler, R. H. 1991. Investor Sentiment and the Closed-End Fund Puzzle. *The Journal of Finance*, 46(1): 75–109.
- Li, A. W. & Bastos, G. S. 2020. Stock market forecasting using deep learning and technical analysis: A systematic review. *IEEE Access*, 8: 185232-185242.
- Lou, H. R., Wang, X., Gao, Y. & Zeng, Q. 2022. Comparison of ARIMA model, DNN model and LSTM model in predicting disease burden of occupational pneumoconiosis in Tianjin, China. *BMC Public Health*, 22(1): 1.
- Malkiel, B. G. 2003. The efficient market hypothesis and its Critics. *Journal of Economic Perspectives*, 17(1): 59–82.
- Moolayil, J. 2019. *Learn Keras for Deep Neural Networks: A Fast-Track Approach to Modern Deep Learning with Python*. New York City: Apress.
- Murphy, J. J. 1999. **Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications**. New York, NY: Penguin Group.
- Odean, T. 1998. Are investors reluctant to realize their losses? *The Journal of Finance*, 53(5): 1775–1798.
- Olsen, R. A. 1998. Behavioral finance and its implications for stock-price volatility. *Financial Analysts Journal*, 54(2): 10–18.
- Öztürk, M. 2015. Heuristic based trading system on forex data using technical indicator rules. *M.S. - Master of Science*. Ankara: Middle East Technical University.
- Pearson, R. K. 1999. Data cleaning for dynamic modeling and control. *1999 European Control Conference (ECC)*, 2584–2589.

- Pele, D. T., Lazar, E. & Dufour, A. 2017. Information Entropy and Measures of Market Risk. *Entropy*, 19(5): 226.
- Prigogine, I. & Stengers, I. 1984. *Order Out of Chaos: Man's New Dialogue with Nature*. New York, NY: Bantam Books.
- Pring, M. J. 2014. *Technical Analysis Explained*. New York, NY: McGraw-Hill Education.
- Rook, L. 2016. An Economic Psychological Approach to Herd Behavior. *Journal of Economic Issues*, 40(1): 75–95.
- Rundo, F., Trenta, F., di Stallo, A. L. & Battiato, S. 2019. Machine learning for quantitative finance applications: A survey. *Applied Sciences (Switzerland)*, 9(24): 5574.
- Sako, K., Mpinda, B. N. & Rodrigues, P. C. 2022. Neural Networks for Financial Time Series Forecasting. *Entropy*, 24(5): 657.
- Samuelson, P. A. 1964. Theoretical Notes on Trade Problems. *The Review of Economics and Statistics*, 46(2): 145-154.
- Samuelson, P. A. 1965. Proof that Properly Anticipated Prices Fluctuate Randomly. *Industrial Management Review Spring*, 6(3): 41–49.
- Schrimpf, A., & Sushko, V. 2019. Sizing up global foreign exchange markets. *BIS Quarterly Review*. [www.bis.org/statistics/rpfx19.htm](http://www.bis.org/statistics/rpfx19.htm), December 19.
- Schwert, G. W. 1989. Why Does Stock Market Volatility Change Over Time? *The Journal of Finance*, 44(5): 1115–1153.
- Segal, T 2023. Fundamental Analysis: Principles, Types, and How to Use It. **investopedia.com**.  
<https://www.investopedia.com/terms/f/fundamentalanalysis.asp>

- 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 Journal*, 90: 106181.
- Shabri, A., Samsudin, R., & Yusoff, Y. 2020. Combining Deep Neural Network and Fourier Series for Tourist Arrivals Forecasting. *IOP Conference Series: Materials Science and Engineering*, 864(1): 012094.
- Shannon, C. E. 1948. A Mathematical Theory of Communication. *Bell System Technical Journal*, 27(4): 623–656.
- Shiller, R. J. 2003. From Efficient Markets Theory to Behavioral Finance. *Journal of Economic Perspectives*, 17(1): 83–104.
- Shiller, R. J. 2016. *Irrational Exuberance*. Princeton, NJ: Princeton University Press.
- Thaler, R. H. 1999. The End of Behavioral Finance. *Financial Analysts Journal*, 55 (6): 12-17.
- Tsay, R. S. 2005. *Analysis of financial time series*. Hoboken, NJ: John Wiley & Sons.
- Xiong, W., Faes, L. & Ivanov, P. C. 2017. Entropy measures, entropy estimators, and their performance in quantifying complex dynamics: Effects of artifacts, nonstationarity, and long-range correlations. *Physical Review E*, 95(6): 062114.
- Zunino, L., Zanin, M., Tabak, B. M., Pérez, D. G. & Rosso, O. A. 2009. Forbidden patterns, permutation entropy and stock market inefficiency. *Physica A: Statistical Mechanics and Its Applications*, 388(14): 2854-2864.