



VIRGÍNIA MARIA FERREIRA DE SOUSA

**APLICAÇÃO DE REDES NEURONAIS À PREVISÃO DE
PREÇOS DE AÇÕES**

Trabalho realizado sob a orientação do
Professor Doutor Hugo Alonso Vilares Monteiro

Janeiro de 2020



Virgínia Maria Ferreira de Sousa

APLICAÇÃO DE REDES NEURONAIIS À PREVISÃO DE PREÇOS DE AÇÕES

Dissertação de Mestrado em Gestão

Dissertação defendida em provas públicas na Universidade Lusófona do Porto no dia 22/01/2020, perante o júri seguinte:

Presidente: Prof.^a Doutora Maria Teresa Ribeiro Candeias (Prof.^a Auxiliar da Universidade Lusófona do Porto);

Arguente: Prof.^a Doutora Cláudia Noémia Soares de Sousa (Prof.^a Auxiliar da Universidade Lusófona do Porto);

Orientador: Prof. Doutor Hugo Alonso Vilares Monteiro (Prof. Associado da Universidade Lusófona do Porto).

Janeiro de 2020

Declaração

É autorizada a reprodução integral desta dissertação apenas para efeitos de investigação, mediante declaração escrita do interessado, que a tal se compromete.

Agradecimentos

Todo o percurso feito até à entrega desta dissertação foi pautado por obstáculos, desafios e momentos de decisão, mas sobretudo por muito trabalho e dedicação.

A conclusão deste trabalho não seria possível sem que algumas pessoas me tivessem acompanhado. Por esta razão, quero deixar uma palavra de agradecimento ao meu orientador, Professor Doutor Hugo Alonso, pela sua competência científica, pelas suas palavras de incentivo, de crítica e de apoio nos momentos mais difíceis e que jamais esquecerei.

Aos meus professores por todo o conhecimento que partilharam durante esta jornada.

Aos meus colegas, em especial a Marta Oliveira, grande companheira neste grande desafio, pela sua amizade e companheirismo.

À minha família, em especial ao meu marido Nuno e às minhas filhas, Valentina e Francisca por compreenderem todos os períodos de ausência dedicados a este projeto e por todo o apoio.

A todos, o meu mais sincero e eterno agradecimento.

Resumo

Ter a capacidade de prever o preço de um determinado título é sem dúvida um grande desafio, quer pela complexidade, quer pela volatilidade implícita dos mercados financeiros. Trata-se de um tema de grande interesse para investigadores e para os agentes dos mercados, pois a eficácia da previsão traduz-se em ganhos monetários avultados.

Esta dissertação tem como objetivo demonstrar a aplicação de redes neuronais à previsão de preços de ações. Foram escolhidos dois títulos financeiros, designadamente a *Apple* e a *Microsoft*. A escolha inicial das variáveis preditoras compreende as mais utilizadas e referenciadas nos trabalhos científicos publicados sobre este tema. Esta dissertação demonstra a importância de uma seleção cuidada de algumas dessas variáveis para um bom desempenho das redes neuronais.

Palavras-chave: Ações, mercado financeiro, redes neuronais, seleção de variáveis.

Abstract

Having the ability to predict the price of a particular stock share is undoubtedly a major challenge, because of the complexity and implied volatility of the financial markets. This is a topic of great interest to researchers and market players, as the effectiveness of the forecast might translate into huge monetary gains.

This dissertation aims to demonstrate the use of neural networks in stock price forecasting. In order to perform this analysis, two financial titles were chosen: *Apple* and *Microsoft*. The initial choice of the predictor variables comprises the most used and referenced in the scientific papers published on this subject. This dissertation demonstrates the importance of a careful selection of some of those variables for a good neural network performance.

Keywords: Stock share, financial markets, neural networks, variable selection.

Índice

Introdução	1
Capítulo 1. Mercados financeiros.....	5
1.1. Origem	6
1.2. O que é o mercado de ações?	8
1.3. Previsão dos mercados.....	8
Capítulo 2. Análise Fundamental e Técnica	11
2.1. Análise Fundamental	12
2.2. Análise Técnica	14
Capítulo 3. Previsão dos preços utilizando redes neuronais	21
3.1. Redes Neuronais.....	22
3.2. Aplicações das redes neuronais nos negócios.....	25
3.3. Vantagens das redes neuronais.....	27
Capítulo 4. Metodologia	29
4.1. Definição do problema	30
4.2. Recolha de dados.....	30
4.3. Análise dos dados.....	34
4.3.1 <i>Apple</i>	34
4.3.2 <i>Microsoft</i>	36
4.4. Desenvolvimento, avaliação, seleção e aplicação de modelos de previsão	37
Capítulo 5. Resultados.....	39
5.1. Previsão do preço das ações da <i>Microsoft</i>	40
5.2. Previsão do preço das ações da <i>Apple</i>	45
Capítulo 6. Conclusões e trabalho futuro	49
Referências Bibliográficas	52
Apêndices.....	57

Índice de apêndices

Apêndice 1 – Matriz de correlações entre potenciais variáveis preditoras – <i>MSFT</i>	1
Apêndice 2 – Matriz de correlações entre potenciais variáveis preditoras – <i>Apple</i>	2

Índice de figuras

Figura 1 - Exemplo de uma MMS de 15 dias (linha vermelha) e uma MMS de 200 dias (linha azul)	16
Figura 2 - Exemplo de uma MME de 15 dias (linha vermelha) e de 200 dias (linha azul) .	17
Figura 3 - Exemplo de uma MME de 200 dias (linha vermelha) e uma MMS 200 dias (linha azul)	17
Figura 4 – Análise gráfica com o volume e <i>Momentum</i> (15 dias)	18
Figura 5 - Rede neuronal multicamada de alimentação direta.....	23

Índice de gráficos

Gráfico 1 – Evolução do preço de fecho da <i>Apple</i> nos últimos 9 anos.....	34
Gráfico 2 – Evolução do preço de fecho da <i>MSFT</i> nos últimos 9 anos	36
Gráfico 3 – Previsões no treino das redes seleccionadas – <i>MSFT</i>	44
Gráfico 4 – Previsões na validação das redes seleccionadas – <i>MSFT</i>	44
Gráfico 5 – Previsões no teste das redes seleccionadas – <i>MSFT</i>	44
Gráfico 6 – Previsões no treino das redes seleccionadas – <i>Apple</i>	48
Gráfico 7 – Previsões na validação das redes seleccionadas – <i>Apple</i>	48
Gráfico 8 – Previsões no teste das redes seleccionadas – <i>Apple</i>	48

Índice de tabelas

Tabela 1 – Variáveis por natureza/empresa	33
Tabela 2 – Medidas estatísticas - variáveis <i>Apple</i> nos últimos 9 anos	35
Tabela 3 – Medidas estatísticas - variáveis <i>Microsoft</i> nos últimos 9 anos	37
Tabela 4 – Resultados do treino, validação e teste com a primeira abordagem de seleção das variáveis preditoras – <i>MSFT</i>	41
Tabela 5 – Importância (%) das variáveis para as redes com a segunda abordagem de seleção das variáveis preditoras – <i>MSFT</i>	42
Tabela 6 – Desempenho das redes com a segunda abordagem de seleção das variáveis preditoras – <i>MSFT</i>	43
Tabela 7 – Resultados do treino, validação e teste com a primeira abordagem de seleção das variáveis preditoras – <i>Apple</i>	46
Tabela 8 - Importância (%) das variáveis para as redes com a segunda abordagem de seleção das variáveis preditoras – <i>Apple</i>	47
Tabela 9 – Desempenho das redes com a segunda abordagem de seleção das variáveis preditoras – <i>Apple</i>	47

Abreviaturas e siglas

MOM – *Momentum*

RSI – *Relative Strength Index*

ROE – *Return on Equity*

MMS – Média Móvel Simples

MME – Média Móvel Exponencial

MSFT – corresponde ao símbolo de identificação da *Microsoft* nas plataformas de *Trading* e consulta de preço

Introdução

A Humanidade sempre teve o desejo de prever o futuro. Será que é possível prever o preço de um título financeiro? Trata-se de um problema complexo, pois os mercados são caracterizados pela sua natureza dinâmica, ambiente imprevisível e flutuam rapidamente em períodos muito curtos (Nigam, 2018). Além disso, é um grande desafio descobrir qual o método mais eficaz para prever o preço das ações numa compra ou numa venda (R.K. & D.D., 2010). A negociação no mercado bolsista/valores recorre a diferentes metodologias para a previsão dos preços e as técnicas de *machine learning*, nas quais se incluem as redes neuronais artificiais, são as mais utilizadas para o efeito (García et al., 2018).

De acordo com Cortez & Neves (2000), uma rede neuronal artificial é “um modelo simplificado do sistema nervoso central do ser humano”. É composta por elementos com capacidade de processamento e com aptidão natural para armazenar conhecimento e torná-lo acessível ao utilizador. É semelhante ao cérebro humano, porque o conhecimento é adquirido através de um processo de aprendizagem. Esse processo é centrado num algoritmo que ajusta a força das conexões entre neurónios até se atingir o objetivo de conhecimento.

Ao contrário de técnicas convencionais de previsão, as redes neuronais artificiais têm a capacidade de resolver problemas não lineares e mal-postos, com mais do que uma solução. São-lhes reconhecidas a sua eficiência, robustez e adaptabilidade, tornando-se assim uma ferramenta valiosa para classificação, suporte à decisão e análise financeira (Tkác & Verner, 2016).

O objetivo desta dissertação é usar redes neuronais artificiais para prever o preço de um título financeiro numa semana, tendo por base informação sobre o título e o mercado na semana anterior. Para alcançar este objetivo, definimos as seguintes tarefas:

- i. Encontrar na literatura as variáveis preditoras comumente usadas na aplicação das redes neuronais;
- ii. Identificar qual a variável ou conjunto dessas variáveis que proporcionam melhores resultados de previsão.

Os instrumentos financeiros selecionados pertencem às seguintes empresas: *Apple Inc.* e *Microsoft Corporation*.

Considerando todos os fatores económicos associados ao contexto atual das empresas, o clima político, as guerras comerciais entre países, entre outros fatores, torna-se difícil investir com um risco baixo, usando apenas a análise técnica e fundamental. A incerteza faz aumentar a volatilidade dos mercados financeiros e torna a previsão dos preços um desafio cada vez maior (Yue-Gang Song, 2018).

Maknickiene et al. (2018), Koolia et al. (2018) e A.A. Adebiyi (2012) demonstraram que o erro de previsão varia de acordo com as variáveis preditoras selecionadas. Maknickiene et al. (2018) constataram que os sentimentos dos investidores influenciam o mercado. Koolia et al. (2018) demonstraram que o contexto político-económico tem impacto negativo na previsão dos preços das ações e que a introdução de uma variável contabilística não melhora a qualidade da previsão neste tipo de contexto. A.A. Adebiyi (2012) também utilizou uma rede neuronal para prever o preço de ações, tendo considerado variáveis técnicas, tais como o volume ou preço, variáveis de natureza fundamental, tais como o *Return on Equity*, e opiniões de especialistas. Este autor verificou que a inclusão da opinião dos especialistas melhora os resultados da previsão. Num outro estudo, Chen & Kutan (2016) analisaram os padrões de negociação da Bolsa de Taiwan e constataram que rumores positivos sobre as empresas cotadas têm um impacto positivo sobre o preço e que rumores negativos têm um impacto negativo.

Visto que o objetivo principal desta dissertação é prever o preço das ações, de preferência com a maior eficácia possível, é fundamental determinar quais as variáveis que poderão ser mais úteis na previsão. Numa primeira abordagem, começamos por considerar para variáveis preditoras as que são habitualmente indicadas na literatura e, visando eliminar informação redundante, conservamos apenas as que não estão fortemente correlacionadas. Numa segunda abordagem, determinamos a importância de todas as variáveis preditoras inicialmente consideradas e, por meio de um processo iterativo, vamos excluindo as menos importantes, até ser atingido o melhor desempenho das redes neuronais ao nível da previsão do preço do título selecionado.

O resto deste trabalho encontra-se organizado em seis capítulos.

No Capítulo 1 são apresentadas algumas considerações sobre mercados financeiros.

Nos Capítulos 2 e 3 encontra-se a revisão da literatura, sendo introduzidos conceitos sobre as análises realizadas para investimento e a descrição da aplicação das redes neuronais ao objetivo proposto nesta dissertação.

No Capítulo 4 são apresentados a metodologia utilizada para a realização do trabalho e os dados considerados.

No Capítulo 5 são mostrados e discutidos os resultados.

Por fim, no Capítulo 6 são fornecidas as conclusões e as perspetivas de trabalho futuro.

Capítulo 1. Mercados financeiros

1.1. Origem

As ações, na sua forma jurídica, terão surgido em Inglaterra em 1533 para financiar a *Muscovy Company*. O pretendido era reunir cerca de 6000 libras e o risco seria partilhado por exploradores, que teriam de enviar navios mercantes com destino à Rússia. Cada um dos exploradores subscreveu uma parte do risco e adquiriu o direito de auferir a sua quota-parte do lucro da exploração. Visto que este sistema foi bem-sucedido, difundiu-se para outras empresas e com outros projetos. Assim, as ações começaram a ser transacionadas na taberna da Rua *Threadneedle*, sede da *London Stock Exchange* (LSE) (Matos, 2005).

A primeira grande queda dos preços, denominada também por *crash*, ocorreu em Londres, em 1720, devido às ações *South Sea*, empresa que se dedicava ao comércio nos mares do Sul. Este título aumentou, em 8 meses, cerca de 1800%, provocando uma “bolha” especulativa. Mais tarde, algo pior aconteceu em França, com ações a valorizarem cerca de 4000% e a caírem 99%. Em Outubro de 1929 acontece em *Wall Street* uma queda de preços mais moderada, no entanto, com repercussão mundial, resultando posteriormente num período de receção económica denominado como o período da Grande Depressão. Uma outra queda violenta de preços deu-se novamente em *Wall Street*, em 1987. De acordo com a comissão nomeada para compreender a origem de tal facto, a queda foi provavelmente desencadeada por programas de computadores que ordenaram vendas automáticas. Uma outra bolha, agora mais recente, foi a criada em torno das empresas tecnológicas por volta do ano 2000, onde as perdas foram superiores a 90% (Matos, 2005).

Em Portugal, foi fundada a primeira bolsa em 1837. Em 1891 foi inaugurada a Bolsa do Porto pelo Rei D. Carlos, com sede no palácio da Bolsa, mandado contruir pela Associação Comercial do Porto. Pela documentação existente destaca-se um *Bull Market* no período de 1970-1974, ou seja, uma queda com a crise petrolífera em finais do ano 1973 e a suspensão da bolsa com o 25 de Abril de 1974, provocando o desaparecimento de dinheiro entre particulares. Em 25 de fevereiro de 1977 a bolsa foi reaberta, embora com uma pequena quantidade de títulos. Em 1986 surgem os primeiros sinais de mudança, onde em bolsa se transacionaram cerca de 10 milhões de contos (aproximadamente 50.000.000 €) e havia 63 empresas cotadas, o triplo das existentes em 1981. Em 1987 o universo de empresas cotadas

em bolsa era de 143 e transacionaram-se em bolsa cerca de 160 milhões de contos (aproximadamente 800.000.000 €). A procura foi tal que o Índice BTA subiu aos 6870 pontos, uma valorização tremenda em 10 anos. Em 17 de Outubro de 1987 deu-se mais um *crash*, onde milhões de contos desapareceram. No início dos anos 90 as bolsas de Lisboa e Porto tornaram-se “modernas”, sendo reguladas pelo Código de Transação de Valores Imobiliário. Surgiram as sociedades financeiras de corretagem e deu-se a privatização da Bolsa e a divulgação de informação em tempo real à Comissão do Mercado de Valores Imobiliários (CMVM). No início do século 20 surgem as primeiras mudanças qualitativas em Portugal, quando a bolsa do Porto é fundida com a bolsa de Lisboa e mais tarde com a *Euronext*, associação dedicada à atividade de gestão de bolsas. A globalização da internet criou profundas mudanças em termos funcionais e oportunidades para os investidores, permitindo-lhes aceder a todos os mercados e transacionar em tempo real (Matos, 2005).

Os investidores dividem-se naqueles que investem de forma sólida, baseados no valor intrínseco da ação e resultando em investimentos lentos, contudo mais seguros para aumentar a riqueza, e em investidores que tentam adivinhar a psicologia do mercado. Este último tipo de investidores está mais interessado em especular o valor futuro dos ativos, do que esperar pacientemente que as ações comprovem o seu valor intrínseco. Este tipo de pensamento leva os mercados a bolhas especulativas e a colapsos. O que acontece é que os preços aumentam porque os investidores pensam que estes títulos irão aumentar no futuro. Se os investidores comprem pensando que o preço vai aumentar, este ato faz com que o preço aumente, devido a esperanças e sonhos e não porque os dividendos ou lucros estão a aumentar. As bolhas especulativas causam sempre grandes colapsos e pânico económico (Samuelson & Nordhaus, 2012).

1.2. O que é o mercado de ações?

O mercado de ações é um local onde os títulos de propriedade das empresas são comprados e vendidos. Estes títulos possuem duas características importantes, designadamente a taxa de rentabilidade e o risco associado. A taxa de rentabilidade é o ganho monetário de um título, ou seja, rendimentos que representam mais ou menos valias associadas à evolução positiva ou negativa do valor do título. Existem títulos com taxas de rentabilidade previsíveis, mas existem outros cujo investimento é muito arriscado. Assim, surge a segunda característica, o risco, que, devido à variabilidade correspondente, pode conduzir à perda de investimento. Quando alguém compra um título desta natureza, por exemplo, no prazo de um ano, não tem a certeza se terá todo o seu valor no final do período (Samuelson & Nordhaus, 2012).

As tendências de mercado de ações são normalmente seguidas usando índices de preços de ações, que são médias ponderadas dos preços de um cabaz de ações de empresas. Os índices mais importantes são o *Dow Jones Industrial Average* (DJIA) que representa 30 grandes empresas, o índice *Standard & Poor's* de 500 sociedades (S&P500) e o *NASDAQ Composite Index* que inclui mais de 3000 ações (Samuelson & Nordhaus, 2012).

1.3. Previsão dos mercados

Considerando todo o contexto económico e a globalização associados aos mercados financeiros, é genericamente aceite que a previsão do preço de ações torna-se um desafio cada vez maior, quer pelo suporte à decisão de investimento, quer pela tentativa de menor exposição ao risco associado a esse investimento realizado (Guihua, 2018; Thawornwong & David Enke, 2004; Lawrence, 1997).

Com o rápido desenvolvimento dos mais variados fatores económicos e principalmente das necessidades de investimento, a previsão do mercado de ações está diretamente relacionada com o ambiente económico e político, a nível internacional, e com a opinião/juízo dos especialistas (Guihua, 2018).

Será que existe uma “bola de cristal” que possa prever o preço das ações? Existem duas teorias de previsibilidade dos mercados: a teoria *Random Walk* e a teoria do mercado eficiente.

A teoria *Random Walk* tem como princípio a impossibilidade de prever o mercado e refere que a probabilidade de subida de um preço é igual à probabilidade de descida. Esta teoria surgiu em 1900 por *Louis Bachelier*. Com o aparecimento das tecnologias e a recolha massiva de dados históricos, passou a ser possível testar esta e outras hipóteses. Desde esta época que o debate sobre esta teoria se mantém. A mesma foi rejeitada pelos académicos e agentes de mercado, que apontavam defeitos na formação dos preços, devido, por exemplo, ao “efeito janeiro” (no início dos anos a tendência é positiva) ou ao “síndrome de fim-de-semana” (porque o otimismo é maior). Assim, existem movimentos de subida ou descida nos quais a maioria das ações acompanham o movimento. Além disso, existem evidências estatísticas que revelam tendências de subida ou descida diretamente relacionadas com os ciclos económicos (Matos, 2005).

Por outro lado, segundo Malkiel (2003), a teoria do mercado eficiente sustenta que não adianta analisar as notícias, padrões de preços ou ciclos económicos para fazer uma previsão dos preços dos movimentos futuros dos preços, porque os preços respondem às surpresas que, de um modo característico, são aleatórias, provocando movimentos erráticos.

Capítulo 2. Análise Fundamental e Técnica

As análises fundamental e técnica auxiliam o investidor na sua tomada de decisão. A segunda não nega a utilidade da primeira, mas coloca-a em segundo plano, porque o preço forma-se, em última análise, pela informação que chega ao mercado e que compreende todos os dados, expectativas, estados de espírito e percepções do investidor (Matos, 2005).

2.1. Análise Fundamental

A análise fundamental compreende o estudo da economia em geral, a relação do mercado de capitais, os setores de atividade e, por fim, as empresas. Esta análise procura saber o valor real das ações, o chamado valor intrínseco, para determinar se está baixo ou alto, dando ordens de compra e venda de acordo com o preço. O objetivo da análise fundamental passa então por determinar o que comprar e o que vender, de preferência comprar barato para vender caro, com base em informações prestadas pelas empresas através dos seus relatórios de contas habituais. Um investidor que se baseie na análise fundamental analisa o estado da economia global no que toca às taxas de juro, inflação ou ao mercado cambial. Depois, concentra-se nos setores de atividade, pois eventuais adversidades podem influenciar o título relacionado com os mesmos. Segue-se então a análise da empresa, onde o investidor individual pode analisar rácios e indicadores que permitam averiguar a situação atual da mesma antes de investir (Matos, 2005).

Existem alguns procedimentos que podem auxiliar o investidor na sua decisão de investimento. A análise do relatório de contas é um procedimento usual, pois permite a análise de rácios económicos e financeiros. O seu estudo permite determinar de forma aproximada o valor intrínseco das ações e uma análise temporal a evolução ano após ano dos valores inscritos nesse relatório.

Entre muitos indicadores fundamentais, na análise de uma empresa, os investidores recorrem ao *PER* – *Price Earnings Ratio*, que é um rácio que indica se a ação está barata ou cara em comparação com o mercado do sector. O rácio, que se prefere baixo, é dado por: $\frac{\text{Preço da ação}}{\text{Ganho por ação}}$. Por referência, um *PER* médio de mercado igual a 10 é considerado baixo e de 20 alto. Este rácio pretende medir o desempenho de uma empresa em função do lucro que obteve, sendo considerada uma medida de grande interesse na avaliação do preço de uma ação (Matos, 2005).

Um rácio igualmente importante é o *ROE – Return on Equity*, que é um indicador que traduz o retorno dos capitais próprios, ou seja, mede o desempenho que a empresa tem para criar retorno dos capitais investidos pelos acionistas (Matos, 2005). É dado por $\frac{\text{Resultado líquido do período}}{\text{Capital próprio}} \times 100$, representa o grau de remuneração dos sócios e determina o retorno que o acionista obtém do seu investimento, sendo considerada uma medida privilegiada para todos os decisores (Neves, 2012).

Uma outra medida de avaliação do preço, também muito utilizada pelos investidores, é o *EPS – Price Earnings per Share*. É um rácio que resulta da divisão do lucro anual, semestral ou trimestral pelo número de ações existentes, ou seja, indica o lucro por ação.

Existem outros rácios, também utilizados por investidores, tais como, *dividend yield (DY)*, *price cash flow (PCF)*, *price book value (PBV)*, *pay out ratio (POR)*, *price book value (PBV)* e *price cash-flow (PCF)*, que permitem auxiliar uma decisão de investimento com menor risco (Matos, 2005).

Apenas a título de curiosidade, Warren Buffet, um dos nomes mais célebres do investimento em ações, utiliza indicadores como o *PER* e o *ROE*, entre outros, na sua estratégia de negociação (Matos, 2005).

Zahedi et al. (2015) utilizaram variáveis contabilísticas para prever os preços do *Tehran Stock Exchange* através da aplicação de modelos de redes neuronais artificiais. Na conclusão, os autores afirmaram que as redes neuronais têm superioridade sobre outros modelos utilizados para o mesmo fim e que conseguem prever com precisão o preço das ações.

No que toca à economia global, um investidor que utilize a análise fundamental para suportar a sua decisão de investimento deve ter em consideração a relação cambial das cotações existentes entre as várias bolsas onde se negociam títulos, pois poderão existir desvalorizações, resultando, assim, numa diminuição de mais-valias. O crescimento do PIB está correlacionado positivamente com a valorização das ações. O défice, a política

monetária, a inflação e a análise da indústria são também indicadores a ter em conta aquando da decisão de investimento (Matos, 2005).

Koolia et al. (2018) demonstraram que o contexto sociopolítico afeta a qualidade da previsão dos preços das ações. Os autores concentraram-se no caso da Tunísia, que teve uma turbulência financeira em Janeiro de 2011. Foi demonstrado que o erro médio de previsão anual dos preços das ações é maior nos eventos ocorridos em Janeiro de 2011, provando que o contexto sociopolítico do país tem impacto negativo na qualidade da previsão dos preços. Revelaram, também, que a introdução de uma variável contabilística melhora a qualidade da previsão dos preços das ações para todos os períodos em estudo, exceto naqueles em que ocorreram os eventos de Janeiro de 2011.

No decorrer da revisão da literatura, verificou-se que são poucos os trabalhos que utilizam indicadores de análise fundamental para previsão dos preços das ações no curto prazo (Erkam et al. 2011; Qui & Song 2016; Koolia et al. 2018; Zahedi et al. 2015), tal como é pretendido neste trabalho, onde o objetivo é realizar uma previsão do preço de uma semana para a seguinte. A generalidade dos trabalhos onde a previsão se faz no curto prazo utilizam indicadores de análise técnica (Adebiyi et al. 2012; Cocianu & Grigoryan, 2015; Garcia et al. 2018; Guihua, 2018; Miranda et al. 2015; Nandakumar et al. 2018; Nayak et al. 2018; Qiu & Song, 2016; Song et al. 2018; Shakya et al. 2018). Por este motivo, reserva-se a próxima secção para descrever esse tipo de análise e os principais indicadores nela considerados.

2.2. Análise Técnica

A análise técnica é uma forma de estudar os preços dos títulos de mercado do lado da oferta e da procura, revelada por séries de preços e volumes. Neste tipo de análise, o valor intrínseco da ação e o estado da economia não interessam. O mais importante é considerar a dinâmica de preços criada pela oferta e pela procura. Este tipo de análise pretende estimar as cotações futuras, através dos preços passados. Normalmente, esta análise é feita através de um gráfico, cuja origem provém do século XVII, dos mercados de arroz, onde os operadores utilizavam um gráfico de “velas” que incorporava os preços praticados durante o dia, desde a abertura até ao fecho do mercado, permitindo de forma visual observar a

evolução dos preços. É de notar que todos os dados de um determinado título estão incorporados no seu preço. Se, por exemplo, uma empresa tiver lucros elevados, a ação vai subir e o analista vai descobri-lo indiretamente, porque a cotação e o volume vão revelar esse aumento da procura (Matos, 2005).

A análise técnica tem a capacidade de prever movimentos futuros utilizando, para o efeito, recursos estatísticos. Permite ao investidor a identificação de tendências e padrões através da formação de preços, fundamentando assim uma decisão de preferência acertada (Silva & Nunes, 2017).

Charles Henry Dow, considerado o pai da análise técnica, fundador do *Wall Street Journal* e criador do índice *Dow Jones*, escreveu um editorial intitulado *Average Movement of Prices*, a primeira aproximação ao estudo dos preços e dos mercados. Em 1986 criou dois índices, o *Industrial* e o *RailRoad*, e sugeriu entrar no mercado quando os índices iniciam uma subida e não entrar quando iniciam uma descida ou mantêm a posição (Matos, 2005).

Prever o preço do mercado de ações é uma tarefa complexa e que atualmente envolve uma forte interação Homem-Máquina. A descida e a subida do preço de ações estão relacionadas com determinados indicadores de desempenho. Os mais habituais são o preço inicial, o de fecho, o mais baixo e o mais alto e o volume de ações negociadas no período de referência (Nandakumar et al., 2018).

O volume é um indicador fundamental em qualquer análise de preços de um determinado título. A análise do volume permite aferir o número de negociações afetas a esse título e permite ajudar, em conjunto com a tendência do preço, a importância das mudanças do preço de um título (Silva & Nunes, 2017).

A análise técnica utiliza a representação gráfica do movimento dos preços ao longo do tempo para observar as subidas e as descidas e quando acontecem. É neste acompanhamento que se decidem os movimentos de compra e venda de um determinado título. Existem muitas ferramentas úteis e comuns na análise de preços para identificação de tendências. Algumas das mais usadas pelos investidores são a média móvel simples, ou MMS (*SMA – Simple Moving Average*), a média móvel exponencial, ou MME (*EMA – Exponential Moving Average*), o momento (*MOM – Momentum*) e o índice de força relativa (*RSI – Relative*

Strength Index) (Silva & Nunes, 2017), que, pela sua importância, descrevemos sumariamente a seguir.

Uma MMS é uma série de números e refere-se a um certo período de tempo escolhido pelo investidor. Cada valor de saída é uma média dos n valores anteriores. As médias móveis tendem a “alisar” os movimentos das cotações, eliminam ruídos e tornam mais evidente o sentido da tendência a curto, médio ou longo prazo (Silva & Nunes, 2017). A Figura 1 mostra duas médias simples referentes a dois períodos distintos, 15 e 200 dias, para as ações da *Apple* entre dezembro de 2017 e abril de 2019. É possível verificar que a MMS de 15 dias acompanha o preço mais de perto quando comparada com a MMS de 200 dias.



Figura 1 - Exemplo de uma MMS de 15 dias (linha vermelha) e uma MMS de 200 dias (linha azul)

Fonte: ProRealTime.com V10.3

Enquanto uma MMS dá a mesma importância a todos os valores envolvidos no seu cálculo, uma MME dá mais relevo aos valores observados mais recentemente, conferindo pesos de crescimento exponencial dos valores mais antigos para os mais atuais. Como consequência, acontecimentos mais recentes refletem-se de uma forma mais rápida numa MME (Silva & Nunes, 2017). A Figura 2 mostra as duas MME referentes aos mesmos períodos e ações consideradas na Figura 1 para as médias simples.



Figura 2 - Exemplo de uma MME de 15 dias (linha vermelha) e de 200 dias (linha azul)

Fonte: ProRealTime.com V10.3

A principal diferença entre os dois tipos de médias móveis é a maior sensibilidade da exponencial a mudanças de preços, conforme se pode verificar na Figura 3.



Figura 3 - Exemplo de uma MME de 200 dias (linha vermelha) e uma MMS 200 dias (linha azul)

Fonte: ProRealTime.com V10.3

O momento indica o movimento de aceleração ou desaceleração dos preços, prevenindo antecipadamente a alteração da tendência. A título de exemplo, para um momento de 15 dias é subtraído o preço de fecho de há 15 dias atrás ao preço de fecho da última sessão, indicando, assim, um valor positivo se o preço está a subir e um valor negativo se o preço está a descer (Silva & Nunes, 2017). Na Figura 4, parte inferior do gráfico, é possível verificar um momento negativo entre meados de outubro de 2018 e janeiro de 2019, pois a linha momento encontra-se abaixo da linha 0, ou seja, apresenta valores negativos. Neste período verifica-se a descida de preço.



Figura 4 – Análise gráfica com o volume e *Momentum* (15 dias)

Fonte: ProRealTime.com V10.3

Por fim, o índice de força relativa representa o número de sessões anteriores em que o título em estudo fechou em subida ou descida. A janela temporal utilizada na análise condiciona a sensibilidade deste indicador, mas o mais comum é o de 14 dias (Silva & Nunes, 2017).

São vários os estudos realizados cujos resultados de previsão são satisfatórios e onde as variáveis utilizadas compreendem indicadores de análise técnica (Muntaser et al., 2017; Qiu & Song, 2016; García et al., 2018). Muntaser et al. (2017) aplicaram redes neuronais na previsão do preço de 3 ações do setor do petróleo e do gás da BM&FBovespa. Utilizaram no seu estudo variáveis relacionadas com o preço, a média móvel, as *bandas de bollinger*, o

volume, o índice *The New York Stock Exchange* (NYSE), o *moving average convergence divergence* (MACD), o indicador *momentum*, índice de força relativa (RSI), entre outros, e concluíram que as redes são eficazes na previsão do preço. Qiu & Song (2016) usaram uma rede neuronal para prever o índice *Nikkei 225*, que é o índice de mercado mais utilizado na bolsa de valores de Tóquio. No seu estudo utilizaram várias variáveis, entre as quais o volume, as médias móveis e o RSI. Por fim, García et al. (2018) usaram uma rede neuronal para prever o índice alemão *DAX-30*, utilizando para o efeito variáveis tais como *momentum* e *RSI*, obtendo também resultados satisfatórios.

Capítulo 3. Previsão dos preços utilizando redes neuronais

Investir no mercado de ações requer muita experiência e capacidade por parte do investidor em escolher o título certo, no momento certo, podendo vir, ou não, a obter grandes ganhos. Ultimamente, os analistas financeiros e gestores têm manifestado interesse pela análise técnica do preço de ações, usando para o efeito redes neuronais artificiais, pois possuem a capacidade de reconhecer indicações ocultas de quando o preço da ação vai subir ou descer (Nigam, 2018).

Este capítulo começa por descrever as redes neuronais artificiais. Em seguida, dá conta de aplicações destas na área dos negócios. Por fim, indica vantagens da sua utilização.

3.1. Redes Neuronais

O objetivo original da investigação em redes neuronais consistiu numa tentativa de perceber e modelar o modo como funciona o cérebro humano. Assim, as redes neuronais artificiais começaram por ser modelos de redes neuronais biológicas, capazes de reproduzir funções básicas do cérebro humano, como o reconhecimento da fala e de imagens. Entretanto, a evolução da investigação conduziu a um afastamento deste propósito original, tendo sido introduzidos novos modelos para resolução de problemas de outra natureza que não biológica, como a previsão de séries temporais (Tealab, 2018), a segmentação de mercado (Badea, 2014), a avaliação do risco de crédito (Nazari & Alidadi, 2013), entre outros. O sucesso das redes neuronais artificiais em resolver problemas é uma consequência das suas características e capacidades. De acordo com (Haykin, 2009; Gama *et al.*, 2017), estes sistemas não lineares, formados por um conjunto intrincado de subsistemas elementares, representativos de neurónios, têm a capacidade de aprender a partir de dados conhecidos, sem assumirem *a priori* hipóteses sobre a distribuição desses dados, e de generalizarem quando são considerados dados novos. Além disso, são robustos na presença de perturbações e podem ser facilmente adaptados para lidar com mudanças num ambiente não estacionário. Mais ainda, eles têm uma estrutura distribuída massivamente paralela, como se ilustra a seguir, que os faz exibir um elevado poder computacional e capturar um comportamento verdadeiramente complexo de uma forma altamente hierarquizada. Apesar de complicados, estes sistemas podem ser aplicados de forma relativamente simples com recurso a *software* como o *Matlab* (*The MathWorks, Inc.*) e o *NeuroSolutions* (*NeuroDimension, Inc.*).

Neste trabalho, consideramos redes neuronais multicamada de alimentação direta (Haykin, 2009). Sejam $x_1, \dots, x_n$ as n entradas e y^{net} a única saída de uma rede neuronal multicamada de alimentação direta com uma camada escondida (intermédia) de m neurónios, como na Figura 5.




Figura 5 - Rede neuronal multicamada de alimentação direta.

Fonte: O autor.

Os neurónios na camada de entrada não processam dados e servem apenas para os dirigir para os neurónios na camada seguinte. Os neurónios na camada escondida têm uma função de ativação sigmoide, nomeadamente a tangente hiperbólica. A saída do i -ésimo neurónio escondido é dada por:

$$z_i = g(x_1, \dots, x_n | w_{i1}, \dots, w_{in}, w_{i0}) = \tanh\left(\sum_{j=1}^n w_{ij}x_j + w_{i0}\right), \quad i = 1, \dots, m,$$

onde w_{ij} é o peso da conexão do j -ésimo neurónio de entrada, com $j = 1, \dots, n$, para o i -ésimo neurónio escondido e w_{i0} é um peso chamado viés do i -ésimo neurónio escondido. O neurónio na camada de saída tem uma função de ativação linear, nomeadamente a identidade. A sua saída é dada por

$$y^{net} = h(z_1, \dots, z_m | w_1, \dots, w_m, w_0) = \sum_{i=1}^m w_i z_i + w_0,$$

onde w_i é o peso da conexão do i -ésimo neurónio escondido, com $i = 1, \dots, m$, para o neurónio de saída e w_0 é um peso chamado viés do neurónio de saída. Assim, a rede neural implementa uma função

$$y^{net} = f(x_1, \dots, x_n | m, \mathbf{w}) = \sum_{i=1}^m w_i \tanh\left(\sum_{j=1}^n w_{ij} x_j + w_{i0}\right) + w_0,$$

parametrizada em m , o número de neurónios escondidos, e $\mathbf{w}$, o vetor dos $m(n+2)+1$ pesos da rede. Os valores destes parâmetros podem ser determinados como se explica a seguir.

Suponhamos que os dados disponíveis para determinar os valores dos parâmetros m e $\mathbf{w}$ da rede neuronal são divididos em dois conjuntos: um conjunto de treino

$$T = \{(x_1^{(T,l)}, \dots, x_n^{(T,l)}; y^{(T,l)})\}_{l=1}^{n_T},$$

com n_T casos, onde $y^{(T,l)}$ é a saída desejada da rede para a entrada $(x_1^{(T,l)}, \dots, x_n^{(T,l)})$, e um conjunto de validação

$$V = \{(x_1^{(V,l)}, \dots, x_n^{(V,l)}; y^{(V,l)})\}_{l=1}^{n_V},$$

com n_V casos, onde $y^{(V,l)}$ é a saída desejada da rede para a entrada $(x_1^{(V,l)}, \dots, x_n^{(V,l)})$. Defina-se o erro de treino como

$$E_T(m, \mathbf{w}) = \sum_{l=1}^{n_T} \left(y^{(T,l)} - f(x_1^{(T,l)}, \dots, x_n^{(T,l)} | m, \mathbf{w}) \right)^2$$

e o de validação como

$$E_V(m, \mathbf{w}) = \sum_{l=1}^{n_V} \left(y^{(V,l)} - f(x_1^{(V,l)}, \dots, x_n^{(V,l)} | m, \mathbf{w}) \right)^2.$$

Fixando $m = k$, para um certo $k \in \mathbb{Z}^+$, seja $\mathbf{w} = \mathbf{w}^{(k)}$ uma solução do problema de mínimos quadrados não lineares

$$\min_{\mathbf{w}} E_T(m = k, \mathbf{w}),$$

encontrada por aplicação de um algoritmo de otimização adequado, como o de Levenberg-Marquardt (Rao, 2009). A sequência dos erros de treino $E_T(m = 1, \mathbf{w} = \mathbf{w}^{(1)})$, $E_T(m = 2, \mathbf{w} = \mathbf{w}^{(2)})$, ... tende a decrescer com m , que é uma medida da complexidade da rede (quanto maior é o valor de m , maior é a complexidade da rede). Por sua vez, a sequência dos erros de validação $E_V(m = 1, \mathbf{w} = \mathbf{w}^{(1)})$, $E_V(m = 2, \mathbf{w} = \mathbf{w}^{(2)})$, ... tende a decrescer até um certo valor de m , digamos $m = k^*$, e depois começa a aumentar. Neste contexto, tomamos $m = k^*$ e $\mathbf{w} = \mathbf{w}^{(k^*)}$ para parâmetros da rede.

3.2. Aplicações das redes neuronais nos negócios

No decorrer destas últimas décadas, as redes neuronais têm sido amplamente utilizadas na área dos negócios, nomeadamente no apoio à tomada de decisões. Ter confiança num sistema de apoio à decisão tornou-se, no contexto atual, uma questão essencial para empresas e as redes neuronais apresentam vantagens quando comparadas com os modelos mais tradicionais, em particular nas situações onde os dados são complexos e os fenómenos não lineares (Tkác & Verner, 2016).

Etheridge et al. (2007, como citado por Tkác & Verner, 2016) realizaram um estudo no âmbito da auditoria e contabilidade e demonstraram que as redes neuronais podem diminuir os custos associados aos erros de classificação em auditorias financeiras realizadas aos clientes. Os resultados obtidos demonstraram evidências de que os padrões ocultos existentes nos dados financeiros podem afetar o processo de tomada de decisão.

Chen et al. (2011, como citado por Tkác & Verner, 2016) utilizaram várias redes para analisar relatórios fiscais incorretos de empresas de construção e demonstraram que a taxa de sucesso nessa análise poderia chegar aos 70%, dependendo de vários fatores, como o tipo de rede utilizada.

Lee & Shih (2009, como citado por Tkác & Verner, 2016) afirmam que à aplicação de redes neuronais na previsão do comportamento do consumidor, o valor destes modelos está na capacidade de simularem a mente humana e estimarem o comportamento do indivíduo com base nas suas características e nas suposições sobre as relações entre variáveis. A

aplicabilidade das redes neuronais inclui a análise da satisfação do cliente e a previsão de gastos, por exemplo, na procura de serviços médicos.

Os mercados cambiais são também uma área onde as redes neuronais são usadas. Este tipo de mercado é muito complexo e está sujeito a “forças” subjacentes que influenciam os dados. Várias arquiteturas de redes neuronais e algoritmos de aprendizagem foram aplicados para prever com sucesso as direções de mudança das taxas de câmbio (Tkác & Verner, 2016).

Outra área onde as redes têm grande aplicabilidade é na previsão de dificuldades e falência financeira. Apesar dos modelos convencionais de classificação das dificuldades financeiras e previsão de falências serem muito populares, as redes neuronais têm ganho terreno e é curioso observar o aumento dos estudos nesta área com as redes após um período de crise financeira, nomeadamente após a crise financeira na Europa devido à dívida soberana (Tkác & Verner, 2016).

Cuadros & Domínguez (2014) utilizaram redes neuronais para segmentar clientes, considerando o cálculo do valor do cliente ao longo da vida, valor atual e fidelidade e demonstraram que o método utilizado é eficaz, ou seja, que o investimento em campanhas de marketing sem saber a referência, peso ou importância dos clientes não é sustentável.

Leia & Ghorbani (2013) utilizaram as redes para detetar comportamentos fraudulentos em comércio eletrónico nas empresas e concluíram que os algoritmos com base neste tipo de aprendizagem são eficazes

As referências indicadas anteriormente sugerem que as redes neuronais são mais eficazes quando comparadas com outros modelos. Em particular, o tipo de rede mais explorado em quase todas as áreas de negócio são as redes neuronais multicamada de alimentação direta, também consideradas nesta dissertação.

3.3. Vantagens das redes neuronais

A capacidade de aprendizagem das redes neuronais e a sua estrutura paralela e hierárquica são duas características essenciais para a resolução de problemas que de outra forma não poderiam ser resolvidos (Cortez & Neves, 2000). Possuem a capacidade de resolver problemas complexos, designadamente no que toca ao tratamento de uma grande quantidade de dados, e fornecem uma previsão excelente para séries temporais (Sharma & Rababaah, 2014). Possuem elevada capacidade de previsão no mercado de ações bem como na previsão de falências (Moghaddama et al., 2016). As investigações sobre redes neuronais mostram que estas possuem o poder de reconhecer e classificar padrões. São adequadas para problemas cujas soluções exigem conhecimento e para as quais existem dados insuficientes. Possuem a capacidade de aprender com a experiência e isso revela-se útil para problemas práticos (Zhang et al., 1998).

Capítulo 4. Metodologia

O objetivo desta dissertação é demonstrar a aplicação de redes neuronais na previsão de preços de ações. O processo de previsão, segundo Montgoméry et al. (2008), engloba várias etapas, designadamente:

1. Definição do problema;
2. Recolha de dados;
3. Análise dos dados;
4. Desenvolvimento, avaliação e seleção de modelos de previsão;
5. Aplicação do(s) modelo(s) selecionado(s) a novos casos.

Em seguida, descreve-se cada uma destas etapas.

4.1. Definição do problema

O problema consiste em usar redes neuronais para prever o preço de títulos financeiros numa semana, tendo por base informação sobre esses títulos e o mercado na semana anterior. Neste contexto, importa decidir sobre que informação deve ser considerada, ou seja, quais as variáveis preditoras que proporcionam melhores resultados de previsão.

4.2. Recolha de dados

Os títulos selecionados neste trabalho foram são as ações da *Apple* e *Microsoft*. A escolha deveu-se ao facto de pertencerem ao importante sector das tecnologias, embora pudessem ter sido selecionados outros títulos de outros sectores. A seleção das variáveis preditoras não foi fácil. No decorrer da revisão da literatura, verificou-se não existir um método que os investigadores utilizassem de forma generalizada na seleção das mesmas. Assim, optou-se por selecionar um conjunto de variáveis que compreende a generalidade dos estudos, designadamente variáveis relacionadas com o preço, sentimentos dos investidores e variáveis contabilísticas. Os dados recolhidos são semanais e dizem respeito ao período entre 8 de janeiro de 2010 e 8 de Março de 2019.

Os dados relativos ao preço e indicadores técnicos considerados neste trabalho foram recolhidos através da *Alphavantage*¹ e *Yahoo*².

A extração dos dados relativos aos sentimentos foi feita através do *Quandl*³, por via de um indicador *Investor Sentiment Survey*, que mede a percentagem de investidores individuais considerados como otimistas, pessimistas ou neutros em relação às suas decisões de mercado. Estes sentimentos foram obtidos através da *American Association of Individual Investors*⁴, uma associação independente, sem fins lucrativos e criada com o objetivo de ajudar os investidores individuais a tornarem-se mais eficientes na gestão dos seus próprios ativos.

É de notar que os sentimentos dos investidores têm tido cada vez mais interesse por parte de investidores e investigadores. Torna-se importante, desta forma, estabelecer uma ligação entre o comportamento individual dos investidores expresso em sentimentos e a dinâmica de mercado. Nas mais recentes décadas existiram um grande número de estudos dedicados a determinar qual a melhor forma para prever a direção da mudança dos mercados e quais as causas da instabilidade dos mercados. Um simples *post* numa rede social pode influenciar o mercado financeiro. Assim, a pesquisa e a medida destes sentimentos e a integração de métodos de *sentiment analysis* são de extrema importância nos mercados financeiros (Maknickiene et al., 2018).

Maknickiene et al. (2018) realizaram um estudo cuja hipótese era averiguar se existia ou não uma relação inequívoca entre a dinâmica de mercado e o sentimento, utilizando para o efeito uma rede neuronal artificial. Os autores investigaram a informação da combinação de duas distribuições de natureza diferente, designadamente, a previsão de opiniões e a previsão dos índices. Os índices analisados foram o NASDAQ, DOW JONES 30 e SPX 500 na periodicidade semanal entre 2010 e 2016. O ativo analisado foi o ouro, em USD. Os sentimentos dos investidores foram classificados como positivos, negativos e neutros para poder determinar a dinâmica de mercado (comprar, vender ou manter, respetivamente). Os

¹ <https://www.alphavantage.co/documentation/> acedido em 16/03/2019

² <https://finance.yahoo.com/> acedido em 02/2019

³ https://www.quandl.com/data/AIIL/AIIL_SENTIMENT-AIIL-Investor-Sentiment-Data acedido em 16/03/2019

⁴ <https://www.aaii.com/> acedido em 17/03/2019

resultados do estudo vêm confirmar que a dinâmica do mercado está diretamente relacionada com os sentimentos dos investidores. Assim, quando os sentimentos são positivos os índices crescem, quando são negativos os índices caem e quando os sentimentos são fracos os índices são estáveis.

Os valores da variável contabilística ROE foram extraídos trimestralmente através do site QUICKFS ⁵. O *QuickFS* é um provedor de dados financeiros para empresas dos EUA, confiável por milhares de investidores profissionais e individuais.

Zahedi & Rounaghi (2015) realizaram um estudo cujo objetivo era prever os preços das ações cotadas na *Tehran Stock Exchange*, através da aplicação de redes neuronais artificiais com 20 variáveis de contabilidade. À semelhança de outros trabalhos, os autores afirmam que este tipo de investigação é cada vez mais importante na economia das nações, também afetada pelo desempenho da bolsa de valores. O estudo concluiu que as redes neuronais têm superioridade sobre outros modelos utilizados para o mesmo fim e que conseguem prever com precisão o preço das ações.

Num outro estudo para previsão dos preços das ações da *Nokia* e da *Dell* da bolsa de valores de *Nova York*, cujas variáveis utilizadas são de análise técnica, fundamental e de opiniões fornecidas pelos “*experts*” do mercado, os autores concluíram que o modelo neuronal proposto é eficaz para melhorar a precisão da previsão do preço das ações, podendo ser usado com sucesso no apoio à decisão na negociação (A.A. Adebisi, 2012).

García et al. (2018) utilizaram indicadores de análise técnica para prever a direção do índice alemão DAX-30 do dia seguinte, utilizando para o efeito os dados do passado. Os resultados do estudo demonstraram que, quanto maior o número de variáveis em modelos neuronais, maior o “ruído” no processo de aprendizagem e pior o desempenho desse modelo ao nível da previsão de novos casos. Criaram modelos com diferentes variáveis, onde utilizaram todos os indicadores ou apenas 2, 3, 5 e 10 indicadores, demonstrando o quão importante é selecionar corretamente as variáveis para uma previsão eficaz.

Nesta dissertação, selecionámos para análise as seguintes variáveis: preço mínimo (*Low*), preço máximo (*High*), preço de abertura (*Open*), preço de fecho (*Close*), volume, *bullish*,

⁵ <https://quickfs.net/> acedido em 15/03/2019

neutral, *bearish*, média móvel simples a 15 e 200 dias (*SMA 15 e 200*), média móvel exponencial a 15 e 200 dias (*EMA 15 e 200*), momento a 15 e 200 dias (*MOM 15 e 200*), índice de força relativa a 15 e 200 dias (*RSI 15 e 200*), *return on equity (ROE)*, índice bolsista (*close_índice*) e *stocksplit* (apenas na *Apple*). Na Tabela 1 indicamos as variáveis selecionadas por empresa de acordo com a sua natureza.

Natureza das variáveis	Apple	Microsoft
Sentimentos dos investidores	<i>Bearish</i>	<i>Bearish</i>
	<i>Bullish</i>	<i>Bullish</i>
	<i>Neutral</i>	<i>Neutral</i>
Contabilísticas	<i>ROE</i>	<i>ROE</i>
Preço	<i>Closep</i>	<i>Closep</i>
	<i>Open</i>	<i>Open</i>
	<i>High</i>	<i>High</i>
	<i>StockSplit</i>	
	<i>Low</i>	<i>Low</i>
Indicadores técnicos	<i>EMA_15</i>	<i>EMA_15</i>
	<i>EMA_200</i>	<i>EMA_200</i>
	<i>MOM_15</i>	<i>MOM_15</i>
	<i>MOM_200</i>	<i>MOM_200</i>
	<i>RSI_15</i>	<i>RSI_15</i>
	<i>RSI_200</i>	<i>RSI_200</i>
	<i>SMA_15</i>	<i>SMA_15</i>
	<i>SMA_200</i>	<i>SMA_200</i>
	<i>volume</i>	<i>volume</i>
Índice	<i>close_índice</i>	<i>close_índice</i>

Tabela 1 – Variáveis por natureza/empresa

Fonte: O autor.

A variável *stocksplit*⁶ foi introduzida para sinalizar a queda abrupta e acentuada de preço verificada apenas no título da *Apple*. Os valores atribuídos a esta variável foram 1 na semana em que ocorreu a queda e 0 nas restantes. Tanto quanto se sabe, nenhum outro estudo previu o preço de uma ação incluindo esta variável.

⁶ Ação corporativa da empresa que compreende a divisão do número de ações em circulação, reduzindo o preço e proporcionando uma faixa de negociação mais acessível para a maioria dos investidores; <https://www.investopedia.com/terms/s/stocksplit.asp> acedido em 10/07/2019

4.3. Análise dos dados

4.3.1 Apple

Relativamente à evolução do preço de fecho da *Apple* nos últimos 9 anos, verifica-se uma tendência crescente até perto do final de 2012. Em meados de 2014, o preço cai abruptamente devido a um *stock split* e, desde então, mantém um comportamento de ligeira subida como pode ser observado no Gráfico 1.




Gráfico 1 – Evolução do preço de fecho da *Apple* nos últimos 9 anos

Fonte: O autor.

A Tabela 2 apresenta algumas estatísticas para as amostras de dados das variáveis consideradas. Por exemplo, é de notar que os sentimentos revelados pelos investidores são positivos, indicando que a tendência é compradora com um consequente aumento do preço do título. Além disso, é curioso verificar, particularmente nas variáveis relacionadas com o preço e de natureza técnica, que o desvio-padrão é elevado, ou seja, que a variabilidade em torno da média é grande.

Natureza das variáveis	Mínimo	1.º Quartil	2.º Quartil	3.º Quartil	Máximo	Média	Desvio-Padrão
<i>Bearish</i>	0,15	0,26	0,30	0,35	0,57	0,31	0,07
<i>Bullish</i>	0,18	0,30	0,36	0,42	0,63	0,36	0,08
<i>close_índice</i>	2101	2918	4396	5360	8088	4460	1660
<i>Closep</i>	90,52	125,61	204,62	422,20	700,10	278,67	173,04
<i>EMA_15</i>	98,01	127,09	207,34	432,49	642,96	278,99	165,39
<i>EMA_200</i>	127,01	183,37	237,31	358,36	450,04	267,05	94,72
<i>High</i>	92,00	128,22	210,12	430,58	705,07	285,63	177,77
<i>Low</i>	89,47	122,74	198,17	414,52	693,62	271,48	168,84
<i>MOM_15</i>	-544,61	-7,32	11,61	32,74	230,35	-1,00	98,81
<i>MOM_200</i>	-601,44	-291,32	107,53	263,63	617,52	8,04	314,30
<i>Neutral</i>	0,14	0,28	0,32	0,37	0,53	0,33	0,06
<i>Open</i>	91,32	124,99	204,30	423,44	699,35	278,08	172,81
<i>ROE</i>	0,21	0,32	0,36	0,45	0,71	0,39	0,12
<i>RSI_15</i>	19,06	43,54	56,36	63,70	85,30	53,61	14,32
<i>RSI_200</i>	45,40	46,44	50,34	57,39	63,81	52,08	5,45
<i>SMA_15</i>	96,65	126,92	208,25	428,81	642,63	279,16	167,55
<i>SMA_200</i>	124,92	169,06	253,93	383,27	460,60	274,52	110,69
<i>StockSplit</i>	0,00	0,00	0,00	0,00	1,00	0,00	0,05
<i>volume</i>	31763500	78388800	119457600	182472764	500362965	138366749	81052755

Tabela 2 – Medidas estatísticas - variáveis *Apple* nos últimos 9 anos

Fonte: O autor.

4.3.2 Microsoft

Como se pode observar no Gráfico 2, o preço de fecho deste título apresenta uma tendência crescente, isto é, tem-se registado uma valorização ao longo do tempo.




Gráfico 2 – Evolução do preço de fecho da MSFT nos últimos 9 anos

Fonte: O autor.

De acordo com a Tabela 3, e à semelhança do que acontece com os dados da *Apple*, os sentimentos dos investidores são positivos, demonstrando assim que a tendência compradora do título é superior à tendência vendedora. Por outro lado, comparando o desvio-padrão da maioria das variáveis com aquele que foi registado para a *Apple*, verifica-se que, no caso da *Microsoft*, a variabilidade dos dados em torno das respetivas médias é, em termos absolutos, menor.

Variáveis	Mínimo	1.º Quartil	2.º Quartil	3.º Quartil	Máximo	Média	Desvio-Padrão
<i>Bearish</i>	0,15	0,26	0,30	0,35	0,57	0,31	0,07
<i>Bullish</i>	0,18	0,30	0,36	0,42	0,63	0,36	0,08
<i>close</i>	23,27	28,88	41,80	60,11	114,37	49,36	25,16
<i>close_indice</i>	2101	2918	4396	5360	8088	4460	1660
<i>EMA_15</i>	23,70	28,99	41,73	60,05	114,75	49,19	25,05
<i>EMA_15</i>	24,96	28,87	41,96	58,12	108,74	48,21	24,10
<i>EMA_200</i>	26,55	27,43	32,69	45,64	78,46	38,69	14,11
<i>high</i>	24,25	29,76	42,79	61,31	116,18	50,29	25,57
<i>low</i>	22,73	28,49	40,83	59,18	112,22	48,18	24,49
<i>MOM_15</i>	-12,98	-0,94	2,13	5,22	16,57	2,43	4,75
<i>MOM_200</i>	-11,26	4,00	16,49	31,15	70,49	19,38	19,95
<i>Neutral</i>	0,14	0,28	0,32	0,37	0,53	0,33	0,06
<i>ROE</i>	-0,30	0,26	0,31	0,39	0,62	0,29	0,17
<i>RSI_15</i>	31,21	49,27	57,94	65,66	84,25	57,57	10,50
<i>RSI_200</i>	46,95	48,61	51,88	54,75	61,78	52,38	4,08
<i>SMA_15</i>	24,61	29,22	41,73	58,26	109,92	48,22	24,16
<i>SMA_200</i>	25,41	26,73	30,95	44,10	72,99	36,99	13,00
<i>volume</i>	50773814	126877169	183165900	255950589	554932000	198827873	89913728

Tabela 3 – Medidas estatísticas - variáveis *Microsoft* nos últimos 9 anos

Fonte: O autor.

4.4. Desenvolvimento, avaliação, seleção e aplicação de modelos de previsão

Para cada um dos títulos selecionados, ou seja, para a *Apple* e *Microsoft*, procedeu-se como descrito a seguir.

O pré-processamento de dados é fundamental para alcançar um bom desempenho preditivo (Maciel & Ballini, 2010). Assim, uma vez que os dados das diferentes variáveis têm ordens de grandeza muito diversas, realizou-se uma transformação dos mesmos no sentido de passarem a ter todos média 0 e desvio-padrão 1.

Em seguida, os dados foram divididos em três partes distintas: treino, validação e teste. Os dados de treino e validação foram usados para determinar, relativamente a um conjunto de variáveis preditoras, os pesos das ligações entre neurónios na rede neuronal e o número de neurónios na camada escondida, conforme explicado anteriormente na Secção 3.1. A ideia

é que, no final do processo de treino e validação, ficam determinados os parâmetros da rede que se estima ter a melhor capacidade de previsão com base nas variáveis preditoras consideradas. Finalmente, a rede obtida é aplicada aos dados de teste, com o objetivo de se avaliar o desempenho dessa rede quando se trata de prever casos que não foram “vistos” antes por ela. O número de casos de treino deve ser o maior possível e representativo da população (Cortez & Neves, 2000). Assim, os dados utilizados para treino correspondem aos anos de 2010 a 2016 (semanas 1 a 365), representando 76% dos casos disponíveis, os dados de validação ao ano de 2017 (semanas 366 a 417) e, por fim, os dados de teste ao ano de 2018 e parte de 2019 (semanas 418 a 480).

A avaliação das redes neuronais foi feita com recurso ao cálculo de duas medidas. A primeira foi o erro percentual absoluto médio, EPAM, definido como:

$$EPAM = \frac{1}{n} \sum_{i=1}^n \left| \frac{P_i - \hat{P}_i}{P_i} \right| \times 100\%,$$

onde P_i representa o preço do título na semana i de n consideradas e $\hat{P}_i$ a previsão fornecida pela rede para esse preço. A segunda medida foi a taxa de acerto na direção do preço, correspondente à percentagem de casos em n considerados em que a rede previu corretamente uma descida, manutenção ou subida do preço.

Por último, a seleção das variáveis preditoras fez-se de acordo com o exposto a seguir. Numa primeira abordagem, começou-se por considerar para variáveis preditoras todas as disponíveis e, tendo por objetivo eliminar informação redundante, conservámos apenas as que não estão fortemente correlacionadas, isto é, entre as quais o coeficiente de correlação de *Pearson* é, em módulo, inferior a 0.9 (Pestana & Gageiro, 2014). Numa segunda abordagem, implementámos um processo iterativo que começa por considerar para variáveis preditoras todas as inicialmente disponíveis e que, em cada iteração, quantifica a importância das variáveis para a previsão da rede treinada, deixando para a iteração seguinte apenas as mais relevantes, com as quais é treinada uma nova rede. A importância das variáveis foi calculada como em (Alonso & Loureiro, 2015).

O *software* usado em todas as experiências computacionais foi o *MatLab R2015a*.

Capítulo 5. Resultados

Neste capítulo apresentamos os resultados da aplicação de redes neuronais artificiais à previsão semanal do preço de fecho das ações das empresas seleccionadas. A saída de cada rede corresponde a uma previsão do preço de fecho numa dada semana e as entradas a informação disponível da semana anterior, como, por exemplo, o volume de ações negociadas. Conforme foi explicado na Secção 4.4, a seleção dessa informação, ou seja, das variáveis preditoras, foi feita seguindo duas abordagens. Na primeira abordagem, começou-se por obter a matriz de correlações entre as variáveis seleccionadas e excluiu-se aquelas que estão fortemente correlacionadas. Na segunda abordagem, eliminou-se sucessivamente as variáveis menos importantes para as redes.

5.1. Previsão do preço das ações da *Microsoft*

Nesta secção apresentamos os resultados da previsão realizada para o título *Microsoft*.

Relativamente à primeira abordagem de seleção das variáveis preditoras, começou-se por obter a matriz de correlações entre as 18 variáveis disponíveis (ver Apêndice 1). Dessas 18, foram excluídas 10 por exibirem uma correlação forte com alguma(s) das restantes. Logo, foram seleccionadas as 8 variáveis seguintes: *closep*, *volume*, *MOM_15*, *RSI_15*, *ROE*, *Bullish*, *Neutral* e *Bearish*. Assim, ficou definido que cada rede neuronal teria essas 8 entradas e o passo seguinte consistiria em decidir qual o número ótimo de neurónios escondidos a considerar. Para tal, foram treinadas e validadas redes com 1 a 5 neurónios escondidos. Conforme é possível verificar na Tabela 4, o erro de previsão no treino diminuiu com o aumento do número de neurónios escondidos e o de validação não melhorou. Assim, entre todas as redes consideradas, seleccionou-se a de 1 neurónio escondido, por ser aquela que apresentou menor erro de validação. Essa rede foi depois aplicada aos dados de teste, tendo-se registado um erro de previsão nesses dados de cerca de 3,5%. Trata-se de um erro baixo, o que permite concluir que a rede tende a fornecer uma boa estimativa semanal do preço de fecho das ações da *Microsoft*. No entanto, se olharmos para a taxa de acerto na direção do preço, verificamos que a rede previu corretamente uma descida, manutenção ou subida do preço em apenas 38,7% dos casos de teste, aproximadamente.

N.º de neurónios escondidos	Erro percentual absoluto médio (%)			Taxa de acerto na direção do preço (%)		
	Treino	Validação	Teste	Treino	Validação	Teste
1	2,2651	1,586	3,4734	58,1267	45,098	38,7097
2	2,1895	1,7472		61,4325	49,0196	
3	2,0852	1,6132		62,259	58,8235	
4	2,0401	1,7336		67,4931	54,902	
5	2,0192	1,6079		67,4931	54,902	

Tabela 4 – Resultados do treino, validação e teste com a primeira abordagem de seleção das variáveis preditoras – *MSFT*.

Fonte: O autor.

Em relação à segunda abordagem de seleção das variáveis preditoras, começou-se por considerar as 18 variáveis disponíveis. Assim, foram treinadas e validadas redes com essas 18 entradas e selecionou-se a rede cujo número de neurónios escondidos, a saber, 1, conduziu ao menor erro de validação. Em seguida, calculou-se a importância dessas 18 variáveis para a rede selecionada e os resultados obtidos constam da Tabela 5. Conforme é possível verificar, a rede 18-1-1 dá muito mais importância às variáveis *Bullish*, *Neutral* e *Bearish* do que às restantes. Isto significa que, quando se trata de prever o preço de fecho das ações da *Microsoft*, numa dada semana, usando informação disponível da semana anterior, a rede 18-1-1 dá muita importância à informação relacionada com os sentimentos dos investidores e pouca importância ao resto. Por exemplo, a variável mais importante é a *Bullish*, com 36% de importância para a rede, e a menos importante é a *MOM_200*, com apenas 0,0002% de importância.

Variáveis	Rede neuronal: N.º de neurónios de entrada-escondidos-saída												
	18-1-1	13-1-1	11-4-1	10-1-1	9-1-1	8-1-1	7-1-1	6-1-1	5-1-1	4-2-1	3-4-1	2-3-1	1-1-1
<i>closep</i>	1,1532	1,8044	2,7417	5,0732	24,4632	23,8314	19,7179	17,3902	57,2294	0,7548	99,4911	99,9686	100
<i>openp</i>	0,0785	0,1041	0,0283	0,1580									
<i>high</i>	0,0166	0,0053											
<i>low</i>	0,0259	0,0000											
<i>volume</i>	0,0009												
<i>SMA_15</i>	0,0346	0,1749	0,5146	7,8809	0,0093	0,0089							
<i>SMA_200</i>	0,0005												
<i>EMA_15</i>	0,0216	0,1167	0,0641	7,6688	0,0363	0,0303	0,0025						
<i>EMA_200</i>	0,0203	0,0512	0,0810	7,6688	0,0010								
<i>MOM_15</i>	0,0010												
<i>MOM_200</i>	0,0001												
<i>RSI_15</i>	0,0144	0,0159	0,0066										
<i>RSI_200</i>	0,0167	0,0260	0,2362	1,9500	0,4003	0,4295	0,3538	0,2846	0,0947				
<i>ROE</i>	0,0002												
<i>Bullish</i>	36,337	37,246	33,0248	22,5897	30,2953	30,5547	32,2992	33,3010	17,3505	38,0749	0,2491		
<i>Neutral</i>	30,827	29,365	31,2697	21,7424	20,8790	21,0452	22,2001	22,8399	11,7834	30,1475			
<i>Bearish</i>	31,377	30,984	31,9349	22,0653	23,5655	23,7475	25,1368	25,9348	13,5420	31,0229	0,2598	0,0314	
<i>Close_indice</i>	0,0751	0,1062	0,0980	4,1427	0,3501	0,3525	0,2896	0,2494					

 Tabela 5 – Importância (%) das variáveis para as redes com a segunda abordagem de seleção das variáveis preditoras – *MSFT*.

Fonte: O autor.

Para o passo seguinte do procedimento de seleção das variáveis preditoras, foram excluídas as variáveis com menor importância, ou seja, *volume*, *SMA_200*, *MOM_15*, *MOM_200* e *ROE*, e consideradas as 13 variáveis restantes. Assim, no novo passo, foram treinadas e validadas redes com essas 13 entradas e selecionou-se a rede cujo número de neurónios escondidos, a saber, 1, conduziu ao menor erro de validação. Em seguida, calculou-se a importância dessas 13 variáveis para a rede selecionada e os resultados obtidos constam da Tabela 6. Para os passos seguintes, foram excluídas, de forma sucessiva, as variáveis menos importantes e mantidas as restantes, ficando-se, no final, com apenas uma variável preditora, nomeadamente, *closep*. Nesse momento, visando comparar o desempenho preditivo das várias redes neuronais selecionadas ao longo dos passos, construiu-se a Tabela 6. Observando-a, é possível verificar que foi a rede 6-1-1 que mostrou ter o menor erro de validação, ou seja, o melhor desempenho preditivo foi atingido por uma rede neuronal que considerou 6 variáveis preditoras, designadamente, *closep*, *RSI_200*, *Bullish*, *Neutral*, *Bearish* e *Close_indice*. Essa rede foi depois aplicada aos dados de teste, tendo-se registado um erro de previsão nesses dados de cerca de 2,2%, isto é, menos 1.3 pontos percentuais do que o erro registado no caso da rede 8-1-1 escolhida no âmbito da primeira abordagem de seleção das variáveis preditoras. Além disso, note-se que a rede 6-1-1 revelou uma taxa de

acerto na direção do preço nos casos de teste muito superior à da rede 8-1-1: 66,1% contra 38,7%. Assim, em cada 3 casos de teste, a rede 6-1-1 foi capaz de prever corretamente uma descida, manutenção ou subida do preço em 2 casos. Tendo em conta a enorme volatilidade do preço das ações, este é um resultado muito positivo.

Rede neuronal: N.º de neurónios de entrada- escondidos-saída	Erro percentual absoluto médio (%)			Taxa de acerto na direção do preço (%)		
	Treino	Validação	Teste	Treino	Validação	Teste
18-1-1	2,2298	2,6957		61,708	47,059	
13-1-1	2,2454	2,7608		60,055	49,020	
11-4-1	1,8622	2,3568		71,901	39,216	
10-1-1	2,2723	1,6817		58,127	49,020	
9-1-1	2,0258	1,3216		58,402	60,784	
8-1-1	2,2502	1,3189		58,678	60,784	
7-1-1	2,2509	1,3142		58,127	58,824	
6-1-1	2,2481	1,2949	2,231	58,678	56,863	66,129
5-1-1	2,3000	2,9214		53,719	39,216	
4-2-1	2,2442	1,7994		60,606	38,710	
3-4-1	2,2059	1,5863		59,504	45,098	
2-3-1	2,2425	2,0608		57,025	37,255	
1-1-1	2,2893	2,6243		54,270	39,2157	

Tabela 6 – Desempenho das redes com a segunda abordagem de seleção das variáveis preditoras – MSFT.

Fonte: O autor.

Os Gráficos 3, 4 e 5 mostram o preço de fecho observado e as previsões das redes 6-1-1 e 8-1-1 nas semanas de treino, validação e teste, respetivamente. No treino e na validação, as previsões de ambas as redes são próximas e estimam bem os valores observados. No entanto, no teste, as previsões da rede 6-1-1 são melhores do que as da rede 8-1-1, que tende a subestimar os valores observados.




Gráfico 3 – Previsões no treino das redes seleccionadas – MSFT.

Fonte: O autor.




Gráfico 4 – Previsões na validação das redes seleccionadas – MSFT.

Fonte: O autor.




Gráfico 5 – Previsões no teste das redes seleccionadas – MSFT.

Fonte: O autor.

Por fim, é de realçar que as redes 6-1-1 e 8-1-1 baseiam as suas previsões em dois conjuntos de variáveis diferentes, já identificadas anteriormente. Há, nesses dois conjuntos, quatro variáveis comuns: *closep*, *Bullish*, *Neutral* e *Bearish*. Estas quatro variáveis são, de facto, as mais importantes para as duas redes. No entanto, enquanto que a rede 6-1-1 atribui-lhes uma importância de 17,4%, 33,3%, 22,8% e 25,9%, a rede 8-1-1 confere-lhes uma importância de 97,2%, 1,1%, 0,7% e 0,9%, respetivamente. É, assim, curioso observar que a rede 6-1-1 dá mais importância aos sentimentos dos investidores e menos importância ao preço de fecho da semana anterior, ao passo que a rede 8-1-1 quase que não dá importância aos sentimentos dos investidores e baseia as suas decisões, quase por completo, no preço de fecho da semana anterior.

5.2. Previsão do preço das ações da *Apple*

Nesta secção apresentamos os resultados da previsão realizada para o título *Apple*.

No que toca à primeira abordagem de seleção das variáveis preditoras, obteve-se a matriz de correlações entre as 19 variáveis disponíveis (ver Apêndice 2), excluíram-se as fortemente correlacionadas e restaram as seguintes: *closep*, *StockSplit*, *volume*, *SMA_200*, *MOM_15*, *MOM_200*, *RSI_15*, *RSI_200*, *ROE*, *Bullish*, *Neutral*, *Bearish* e *Close_indice*. Assim, todas as redes neuronais a considerar teriam estas 13 entradas. Seguidamente, treinou-se e validou-se redes com 1 a 4 neurónios escondidos. De acordo com a Tabela 7, é possível verificar que o erro de previsão no treino foi mais baixo para um número de neurónios escondidos mais elevado e o de validação não melhorou com o aumento desse número de neurónios. Deste modo, selecionou-se a rede de 1 neurónio por ser a que apresentou o menor erro de validação. Esta rede foi posteriormente aplicada aos dados de teste, tendo-se obtido um erro de previsão nesses dados de 10,28%. É um erro ligeiramente alto, quando comparado, por exemplo, com os resultados da *Microsoft*. Contudo, se verificarmos a taxa de acerto na direção do preço, verificamos que a rede previu corretamente a tendência da cotação da ação em 53,23% dos casos de teste.

N.º de neurónios escondidos	Erro percentual absoluto médio (%)			Taxa de acerto na direção do preço (%)		
	Treino	Validação	Teste	Treino	Validação	Teste
1	3,0677	4,7122	10,2820	50,1377	54,9020	53,2258
2	3,1640	9,8945		50,1377	54,9020	
3	2,9076	25,5867		55,3719	60,7843	
4	3,0561	54,5455		11,0573	72,5490	

Tabela 7 – Resultados do treino, validação e teste com a primeira abordagem de seleção das variáveis preditoras – *Apple*.

Fonte: O autor.

No que toca à segunda abordagem de seleção das variáveis preditoras, começou-se por considerar as 19 variáveis disponíveis. Depois, treinou-se e validou-se redes com essas 19 entradas e selecionou-se a rede cujo número de neurónios escondidos conduziu ao menor erro de validação e que foi a rede de 1 neurónio. Em seguida, calculou-se a importância das 19 variáveis para a rede selecionada e os resultados obtidos constam da Tabela 8. A variável *Bullish* foi a mais importante para a rede, com uma importância de 37,37%, e as variáveis *MOM_15*, *MOM_200*, *RSI_15*, *ROE* e *volume* as menos importantes, com uma importância atribuída de 0%, aproximadamente. Os restantes indicadores de análise técnica também tiveram pouca importância para a rede. De seguida, excluíram-se as variáveis preditoras com menor importância e considerou-se para a criação das próximas redes as restantes 14 variáveis. Depois de treinadas e validadas, selecionou-se a rede cujo número de neurónios escondidos conduziu ao menor erro de validação, a saber, 1. Subsequentemente, calculou-se a importância das 14 variáveis para a rede selecionada e resultados constam da Tabela 9. Posteriormente, foram excluídas, de forma sucessiva, as variáveis menos importantes e mantidas as restantes, ficando, no final, com apenas uma variável preditora, nomeadamente, *Bullish*. A Tabela 9 mostra o desempenho preditivo das várias redes neuronais selecionadas ao longo dos passos. É possível observar que a rede 4-3-1 foi a que, comparativamente com as restantes, demonstrou melhores resultados, apresentando um erro médio de validação de 2,05%, rede esta que considerou apenas 4 variáveis preditoras, a saber, *closep*, *Bullish*, *Neutral* e *Bearish*. Esta rede foi aplicada aos dados de teste, onde se registou um erro de previsão de 3,31%, menos 6,97 pontos percentuais quando comparado com o da primeira abordagem. Note-se que o resultado da taxa de acerto foi de 51,61% contra os 53,23% obtidos na primeira abordagem. É assim possível concluir que, em cada 2 casos de teste, ambas as redes preveem corretamente a direção do preço em apenas 1 caso.

Variáveis	Rede neuronal: N.º de neurónios de entrada-escondidos-saída										
	19-1-1	14-1-1	11-1-1	10-1-1	8-1-1	7-1-1	5-1-1	4-3-1	3-4-1	2-1-1	1-1-1
<i>closep</i>	3,0772	3,3370	3,2645	3,5403	2,6841	7,7507	6,3939	0,0329			
<i>StockSplit</i>	0,0435	0,0456	0,0447	0,0468	0,0358						
<i>openp</i>	0,4091	0,4369	0,4251	0,4545	0,3054	0,2988	6,3938				
<i>high</i>	0,1972	0,2642	0,2581	0,2830	0,2105	0,0568					
<i>low</i>	0,4487	0,4076	0,4005	0,4261	0,2952	0,0883					
<i>volume</i>	0,0001										
<i>SMA_15</i>	0,0019	0,0004									
<i>SMA_200</i>	0,0007	0,0005									
<i>EMA_15</i>	0,0014	0,0002									
<i>EMA_200</i>	0,0015	0,0010	0,0001								
<i>MOM_15</i>	0,0000										
<i>MOM_200</i>	0,0000										
<i>RSI_15</i>	0,0000										
<i>RSI_200</i>	0,0024	0,0033	0,0001	0,0014							
<i>ROE</i>	0,0001										
<i>Bullish</i>	37,3690	36,4930	36,5250	36,4300	37,4000	34,7730	35,3730	34,8890	33,6262	94,4550	100
<i>Neutral</i>	28,2700	28,9360	28,9660	28,8310	28,6580	28,1650	28,7300	28,6280	33,1150		
<i>Bearish</i>	30,1760	30,0730	30,1120	29,9860	30,4120	28,8680	29,4200	29,2180	33,2588	5,5446	
<i>Close_indice</i>	0,0012	0,00130	0,0011	0,0007							

Tabela 8 - Importância (%) das variáveis para as redes com a segunda abordagem de seleção das variáveis predictoras – *Apple*.

Fonte: O autor.

Rede neuronal: N.º de neurónios de entrada- escondidos-saída	Erro percentual absoluto médio (%)			Taxa de acerto na direção do preço (%)		
	Treino	Validação	Teste	Treino	Validação	Teste
19-1-1	3,085	5,549		55,6474	70,5882	
14-1-1	3,1014	4,3409		53,9945	70,5882	
11-1-1	3,0838	3,3821		54,27	70,5882	
10-1-1	3,1131	3,2914		55,3719	70,5882	
8-1-1	3,048	2,1633		54,8209	47,0588	
7-1-1	4,7415	2,2802		56,1983	39,2157	
5-1-1	4,7517	2,2289		55,3719	41,1765	
4-3-1	4,7289	2,0481	3,3121	50,4132	58,8235	51,6129
3-4-1	175,9686	111,5133		62,5344	64,7054	
2-1-1	180,0657	118,148		59,7796	66,6667	
1-1-1	153,7755	122,4824		58,9532	60,7843	

Tabela 9 – Desempenho das redes com a segunda abordagem de seleção das variáveis predictoras – *Apple*.

Fonte: O autor.

Nos Gráficos 6, 7 e 8, podemos visionar o preço observado e as previsões das redes 4-3-1 e 13-1-1 nos casos de treino, validação e teste, respetivamente. Nos casos de treino, pode-se verificar que as previsões das duas redes estão próximas do preço observado. No entanto, o mesmo não acontece nos casos de validação e de teste. De facto, nestes casos, apenas a rede 4-3-1 revela uma boa capacidade preditiva; a rede 13-1-1 tende a sobrestimar o preço. Note-se que o número de variáveis predictoras na rede 4-3-1 é muito menor do que o existente na rede 13-1-1, ou seja, a rede 4-3-1 prevê melhor com base em menos informação. O que é curioso observar é que ambas as redes dão mais importância aos sentimentos dos investidores e menos importância às restantes variáveis.




Gráfico 6 – Previsões no treino das redes seleccionadas – *Apple*.

Fonte: O autor.




Gráfico 7 – Previsões na validação das redes seleccionadas – *Apple*.

Fonte: O autor.




Gráfico 8 – Previsões no teste das redes seleccionadas – *Apple*.

Fonte: O autor.

Capítulo 6. Conclusões e trabalho futuro

Esta dissertação teve como principal objetivo ilustrar a aplicação de redes neuronais artificiais à previsão do preço de títulos financeiros. Para o efeito, foram selecionados os títulos da *Apple* e da *Microsoft*, dois gigantes da área tecnológica.

O trabalho realizado incluiu o estudo e programação de redes neuronais e uma revisão de literatura sobre mercados financeiros e sobre as análises que auxiliam o investidor na sua tomada de decisão, nomeadamente, a análise fundamental e a técnica. Verificou-se que as variáveis preditoras consideradas pelos investidores, ou seja, a informação que usam para prever o preço de títulos financeiros, variam bastante de estudo para estudo. Além disso, constatou-se que nem sempre mais variáveis era sinónimo de melhores resultados de previsão e que, por este motivo, havia uma preocupação em selecionar uma parte das variáveis disponíveis por forma a obter os melhores resultados possíveis. No entanto, concluiu-se que a seleção é, regra geral, realizada numa base de tentativa e erro. Assim, nesta dissertação, decidiu-se testar duas abordagens à seleção automática de variáveis preditoras. Na primeira abordagem, foram consideradas para variáveis preditoras todas aquelas que, entre as variáveis disponíveis, não estão fortemente correlacionadas, isto é, que, de certa forma, fornecem informações relativamente independentes para previsão do preço. Na segunda abordagem, foi quantificada a importância das variáveis disponíveis para os modelos de previsão desenvolvidos e, por meio de um processo iterativo, foram excluídas sucessivamente as menos importantes. Tanto quanto se sabe, esta segunda abordagem nunca havia sido testada no contexto da previsão do preço de títulos financeiros. Aquilo que se veio a verificar com as experiências realizadas foi que os melhores resultados de previsão do preço, quer para a *Apple*, quer para a *Microsoft*, foram obtidos pela segunda abordagem. No entanto, não há bela sem senão. De facto, a segunda abordagem é mais exigente do ponto de vista computacional e o tempo que leva a produzir resultados com redes neuronais é elevado. Por este motivo, não foi possível, na janela temporal reservada para elaboração desta dissertação, realizar experiências com outros títulos. Uma conclusão a que foi possível chegar com os dois títulos selecionados foi que, independentemente da abordagem utilizada na seleção de variáveis, as redes neuronais obtidas dão mais importância às variáveis que estão relacionadas com os sentimentos dos investidores e menos importância às variáveis técnicas e contabilísticas. Entre os dois títulos, foi na *Microsoft* que se registaram os melhores resultados de previsão do preço.

No futuro, seria desejável realizar experiências com outros títulos, também de outros setores de atividade, procurando corroborar algumas das conclusões obtidas neste estudo, designadamente, que as variáveis preditoras devem ser selecionadas com base na sua importância para os modelos de previsão. Além disso, seria desejável considerar dados com outra periodicidade que não semanal.

Referências Bibliográficas

- A.A. Adebiyi, C. A. (2012). An Improved Stock Price Prediction using Hybrid Market Indicators. *African Journal of Computing & ICT*, 109, 124-135.
- Alphavantage. 2019. Indicadores de natureza técnica . Retrieved from <https://www.alphavantage.co/documentation/>
- American Association of Individual Investors. 2019. Retrieved from <https://www.aaii.com/>
- Alonso, H., & Loureiro, A. (2015). Predicting flight departure delay at Porto Airport: A preliminary study. *7th International Joint Conference on Computational Intelligence* (pp. 93-98). Lisboa, Portugal: SCITEPRESS.
- Badea, L. M. (2014). Predicting Consumer Behavior with Artificial Neural Networks *Procedia Economics and Finance*, 15, 238 - 246.
- Chen, C.-D., & Kutan, A. M. (2016). Information Transmission Through Rumors in Stock Markets: A New Evidence. *JOURNAL OF BEHAVIORAL FINANCE*, 17:4, 365–381.
- Cortez, P., & Neves, J. G. (2000). Redes neuronais artificiais. Retrieved from <https://www.researchgate.net/publication/242674791>
- Cuadros, A. J., & Domínguez, V. E. (2014). Customer segmentation model based on value generation for marketing strategies formulation. *Estudios Gerenciales*, 30 , 25-30.
- Gama, J., Lorena, A. C., Faceli, K., Oliveira, M., & Carvalho, A. P. (2017). *Extração de Conhecimento de Dados Data Mining (3ª Edição)*. Lisboa, Portugal: Edições Sílabo.

- GARCÍA, F., GUIJARRO, F., OLIVER, J., & TAMOŠIŪNIENĖ, R. (2018). HYBRID FUZZY NEURAL NETWORK TO PREDICT PRICE DIRECTION IN THE GERMAN DAX-30 INDEX. *Technological and Economic Development of Economy*, 2161–2178.
- Guihua, X. (2018). A novel stock price forecasting method using the dynamic neural network. *International Conference on Robots & Intelligent System* (pp. 242-245). Amsterdam, Netherlands: ACM .
- Haykin, S. O. (2009). *Neural Networks and Learning Machines (3rd Edition)*. New Jersey: Pearson Education, Inc.
- Investopedia. 2019. Significado da variável *StockSplit*. Retrieved from <https://www.investopedia.com/terms/s/stocksplit.asp>
- Koolia, C., Trabelsia, R., & Tlili, F. (2018). The impact of accounting disclosure on emerging stock market prediction in an unstable socio-political context. *Accounting Management Information Systems*, 313-329.
- Lawrence, R. (1997). Using Neural Networks to Forecast Stock Market Prices.
- Leia, J. Z., & Ghorbani, A. A. (2013). Improved competitive learning neural networks for network intrusion and fraud detection . *Neurocomputing*, 75, 135-145.
- MACIEL, L. S., & BALLINI, R. (2010). NEURAL NETWORKS APPLIED TO STOCK MARKET FORECASTING: AN EMPIRICAL ANALYSIS. *Learning and Nonlinear Models (L&NLM) – Journal of the Brazilian Neural Network Society*, 8, 3-22.
- Maknickiene, N., Lapinskaite, I., & Maknickas, A. (2018) Application of ensemble of recurrent neural networks for forecasting of stock market sentiments. *EQUILIBRIUM - Quarterly Journal of Economics and Economic Policy*, 13, 2353-3293.

- Malkiel, B. G. (2003). The Efficient Market Hypothesis and Its Critics. *Journal of Economic Perspectives*, 17, 59 – 82.
- Matos, F. B. (2005). *GANHAR EM BOLSA*. Lisboa, Portugal: Publicações Dom Queixote.
- Moghaddama, A. H., Moghaddamb, M. H., & Esfandyaric, M. (2016). Stock market index prediction using artificial neural network. *Journal of Economics, Finance and Administrative Science*, 21, 89–93.
- MONTGOMERY, D. C., JENNINGS, C. L., & KULAHCI, M. (2008). *Introduction to Time Series Analysis and Forecasting* . Retrieved from <http://www.stat.ipb.ac.id/en/uploads/KS/S2%20-%20ADW/3%20Montgomery%20-%20Introduction%20to%20Time%20Series%20Analysis%20and%20Forecasting.pdf>
- Muntaser, J. G., Silva, V. P., & Penedo, A. S. (2017). Aplicação de Redes Neurais na Previsão das Ações do Setor de Petróleo e Gás da Bm&FBovespa. (T. K. Rodrigues, Ed.) *REVISTA FSA*, 14, 49-71.
- Nandakumar, R., R, U. K., R, V., & Lokeswari, Y. V. (2018). Stock Price Prediction Using Long Short Term Memory. *International Research Journal of Engineering and Technology (IRJET)*, 5, 3342-3348.
- Nazari, M. & Alidadi, M. (2013). Measuring credit risk of bank customers using artificial neural network. *Journal of Management Research*, 5(2), 17 - 27.
- Neves, J. C. (2012). *Análise e Relato Financeiro - Uma visão integrada de Gestão*. Lisboa, Portugal: Texto Editores, Lda.

- Nigam, S. (2018). A Soft Computing Technique for Stock Price Prediction. *7th Annual International Conference on Computational Mathematics, Computational Geometry & Statistics (CMCGS 2018)*, (pp. 103-106), Singapore: GSTF.
- Pestana, M. H., & Gageiro, J. N. (2014). *Análise de Dados para Ciências Sociais - A Complementaridade do SPSS (6ª Edição)*. Lisboa, Portugal: Edições Sílabo.
- Qiu, M., & Song, Y. (2016). Predicting the Direction of Stock Market Index Movement Using an Optimized Artificial Neural Network Model. *PLOS ONE*, 1-11.
- Quandl. 2019 . Extração de dados de sentimentos de investidores . Retrieved from https://www.quandl.com/data/AAIL/AAIL_SENTIMENT-AAIL-Investor-Sentiment-Data
- Quickfs. 2019. Indicadores contabilísticos. Retrieved from <https://quickfs.net/>
- Rao, S. S. (2009). *Engineering Optimization: Theory and Practice* (4th edition). New Jersey: John Wiley & Sons, Inc.
- R.K., D., & D.D., P. (2010). Application of Artificial Neural Network for stock market predictions: A review of literature. *International Journal of Machine Intelligence*, 2, 14-17.
- Samuelson, P. A., & Nordhaus, W. D. (2012). *Economia 19e* (19 ed.). AMGH Editora Ltda.
- Sharma, D. K., & Rababaah, A. R. (2014). STOCK MARKET PREDICTIVE MODEL BASED ON INTEGRATION OF SIGNAL PROCESSING AND ARTIFICIAL NEURAL NETWORK. *Academy of Information and Management Sciences Journal*, Number 1, 17.
- Silva, M. G., & Nunes, P. F. (2017). *Ganhar na bolsa*. Lisboa, Portugal: Bookout.

- Thawornwong, S., & David Enke. (2004). Forecasting Stock Returns with Artificial Neural Networks. Em G. Peter Zhang (Ed.), *Neural Networks in Businesses Forecasting*, (pp. 47-49).
- Tealab, A. (2018). Time series forecasting using artificial neural networks methodologies: A systematic review. *Future Computing and Informatics Journal*, 3(2), 334 – 340.
- Tkác, M., & Verner, R. (2016). Artificial neural networks in business: Two decades of research. *Applied Soft Computing*, 38, 788-804.
- Yahoo. (2019) . Yahoo Finance. Retrieved from <https://finance.yahoo.com/>
- Yue-Gang Song, Y.-L. Z.-J. (2018). Neural networks for stock price prediction. *Journal of Difference Equations and applications* (To appear).
- Zahedi, J., & Rounaghi, M. M. (2015). Application of artificial neural network models and principal component analysis method in predicting stock prices on Tehran Stock Exchange. *Physica A*, 438, 178-187.
- Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14, 35–62.

Apêndices

Aplicação de redes neurais à previsão de preços de ações

Apêndice 1 – Matriz de correlações entre potenciais variáveis preditoras – MSFT

Variáveis	closep	openp	high	low	volume	SMA_15	SMA_200	EMA_15	EMA_200	MOM_15	MOM_200	RSI_15	RSI_200	ROE	Bullish	Neutral	Bearish	Close_indice
closep	1	0.9981	0.9992	0.9992	-0.5446	0.9949	0.9873	0.9966	0.9888	0.4858	0.9822	0.4678	0.9691	-0.1425	-0,1088	0.2418	-0,0964	0.9595
openp		1	0.9992	0.9989	-0.5379	0.9958	0.9874	0.9973	0.9891	0.4740	0.9799	0.4511	0.9657	-0.1425	-0,1121	0.2408	-0,0918	0.9573
high			1	0.9989	-0.5318	0.9961	0.9879	0.9976	0.9897	0.4751	0.9809	0.4541	0.9665	-0.1441	-0,1141	0.2409	-0,0897	0.9574
low				1	-0.5523	0.9944	0.9871	0.9962	0.9883	0.4871	0.9819	0.4669	0.9691	-0.1411	-0,1076	0.2446	-0,1003	0.9601
volume					1	-0.5251	-0.5126	-0.5294	-0.5124	-0.3895	-0.5896	-0.4613	-0.6340	0.3091	0,0575	-0.4114	0,3063	-0.6460
SMA_15						1	0.9914	0.9997	0.9941	0.4133	0.9762	0.3950	0.9541	-0.1387	-0,1347	0.2281	-0,0552	0.9507
SMA_200							1	0.9920	0.9990	0.3910	0.9667	0.3719	0.9355	-0.1118	-0,1461	0.2223	-0,0373	0.9390
EMA_15								1	0.9945	0.4265	0.9781	0.4064	0.9570	-0.1393	-0,1312	0.2328	-0,0633	0.9533
EMA_200									1	0.3814	0.9684	0.3624	0.9350	-0.1157	-0,1482	0.2260	-0,0383	0.9387
MOM_15										1	0.4799	0.8264	0.5790	-0.1256	0,1147	0.1809	-0,2907	0.5066
MOM_200											1	0.4823	0.9718	-0.2133	-0,1228	0.2883	-0,1228	0.9656
RSI_15												1	0.5803	-0.1090	0,1956	0.1817	-0,3815	0.4981
RSI_200													1	-0.2587	-0,1093	0.3297	-0,175	0.9853
ROE														1	0,1396	-0.3160	0,1289	-0.2776
Bullish															1	-0.5244	-0,6422	-0.1332
Neutral																1	-0,3159	0.3670
Bearish																	1	-0.1820
Close_indice																		1

Legenda: - correlações fortes, ou seja, superiores, em módulo, a 0,9.

Apêndice 2 – Matriz de correlações entre potenciais variáveis preditoras – Apple

Variáveis	closep	StockSplit	openp	high	low	volume	SMA_15	SMA_200	EMA_15	EMA_200	MOM_15	MOM_200	RSI_15	RSI_200	ROE	Bullish	Neutral	Bearish	Close_indice
closep	1	0.0971	0.9974	0.9989	0.9991	-0.6322	0.9477	0.1627	0.9624	0.4748	0.2911	0.8844	0.3132	0.8413	-0.0835	0.1568	-0.3126	0.1067	-0.5549
StockSplit		1	0.0943	0.0942	0.0952	-0.0449	0.0780	0.0770	0.0831	0.0885	0.0562	0.0550	0.0625	0.0389	-0.0246	0.0177	0.0383	-0.0542	-0.0046
openp			1	0.9991	0.9987	-0.6274	0.9502	0.1645	0.9645	0.4774	0.2824	0.8833	0.2968	0.8370	-0.0876	0.1514	-0.3161	0.1159	-0.5555
high				1	0.9988	-0.6238	0.9499	0.1627	0.9643	0.4757	0.2851	0.8848	0.3016	0.8402	-0.0837	0.1528	-0.3174	0.1154	-0.5577
low					1	-0.6374	0.9486	0.1657	0.9632	0.4778	0.2881	0.8822	0.3088	0.8373	-0.0864	0.1558	-0.3091	0.1047	-0.5518
volume						1	-0.5721	0.2169	-0.5765	-0.0184	-0.3005	-0.5854	-0.4982	-0.6358	0.1166	-0.1869	0.2536	-0.0200	0.3423
SMA_15							1	0.2526	0.9971	0.5768	0.0255	0.8594	0.1197	0.7636	-0.1349	0.1361	-0.3044	0.1223	-0.5554
SMA_200								1	0.2549	0.9104	-0.3002	-0.0258	-0.5531	-0.2330	-0.2655	-0.0486	0.3148	-0.2293	-0.1821
EMA_15									1	0.5800	0.0646	0.8699	0.1370	0.7762	-0.1334	0.1506	-0.3108	0.1120	-0.5614
EMA_200										1	-0.2934	0.3069	-0.4631	0.0410	-0.2552	0.0591	0.1240	-0.1774	-0.2463
MOM_15											1	0.1932	0.6580	0.3668	0.1680	0.0131	-0.0592	0.0387	-0.0746
MOM_200												1	0.2538	0.8823	-0.0129	0.2370	-0.4568	0.1471	-0.5836
RSI_15													1	0.4751	0.0520	0.0976	-0.1454	0.0222	-0.0361
RSI_200														1	0.0160	0.2200	-0.4987	0.2038	-0.7259
ROE															1	0.0412	-0.0497	-0.0011	0.1825
Bullish																1	-0.5244	-0.6422	-0.1332
Neutral																	1	-0.3159	0.3670
Bearish																		1	-0.1820
Close_indice																			1

Legenda: - correlações fortes, ou seja, superiores, em módulo, a 0,9.