

Avaliação de Indicadores e Estratégias no Mercado
Forex com base em Redes Neurais

Mestrado em Finanças Empresariais

Rafael Sambado Areias

Leiria, março de 2025

**Avaliação de Indicadores e Estratégias no Mercado
Forex com base em Redes Neurais**

Mestrado em Finanças Empresariais

Rafael Sambado Areias

Dissertação de Mestrado realizada sob a orientação da Professora Doutora Elisabete Duarte
e do Professor Doutor Carlos Silva

Versão corrigida após prova pública de defesa da dissertação

Leiria, março de 2025

Originalidade e Direitos de Autor

A presente dissertação de projeto é original, elaborada unicamente para este fim, tendo sido devidamente citados todos os autores cujos estudos e publicações contribuíram para a elaborar.

Reproduções parciais deste documento serão autorizadas na condição de que seja mencionado o Autor e feita referência ao ciclo de estudos no âmbito do qual foi realizado, a saber, Curso de Mestrado em Finanças Empresariais, no ano letivo 2024/2025 da Escola Superior de Tecnologia e Gestão do Instituto Politécnico de Leiria, Portugal, e, bem assim, à data das provas públicas que visaram a avaliação deste trabalho.

Agradecimentos

Primeiramente, gostaria de expressar o meu especial agradecimento à minha esposa pelo apoio e por me incentivar sempre a concluir esta dissertação.

Agradeço igualmente aos meus professores, Professor Doutor Carlos Silva e Professora Doutora Elisabete Duarte, pela orientação e pelos conhecimentos partilhados ao longo do percurso.

Um agradecimento especial à empresa Fravizel pelo auxílio prestado.

Por fim, à minha família, pela ajuda e suporte constante. A todos o meu sincero obrigado.

Resumo

Esta dissertação analisa a eficácia de diferentes estratégias de análise técnica no mercado *Forex*, utilizando Redes Neurais para prever movimentos de preços. Foram testadas várias estratégias de Médias Móveis Exponenciais, *Relative Strength Index* (RSI), *Moving Average Convergence / Divergence* (MACD) e *Bollinger Bands*® nos pares cambiais EUR/USD, EUR/ZAR, AUD/CAD, GBP/JPY, NZD/CHF, USD/BRL no período de 1999 a 2023, e consideradas várias configurações de Redes Neurais.

Os resultados indicam que as Redes Neurais podem reproduzir relativamente bem a estratégia ótima a adotar nos pares cambiais analisados. Foram obtidas taxas de precisão média de 82%. A pesquisa contribui para a literatura sobre previsões financeiras e negociação algorítmica, demonstrando o potencial das Redes Neurais como ferramenta para negociação no *Forex*. A dissertação conclui que, apesar das limitações atuais, as Redes Neurais têm potencial significativo para aplicação em estratégias de negociação no *Forex*, mas requerem aprimoramento contínuo.

Palavras-chave: *Forex*, Redes Neurais, Análise Técnica, RSI, MACD, *Bollinger Bands*®.

Abstract

This dissertation analyzes the effectiveness of different technical analysis strategies in the Forex market, using neural networks to predict price movements. Various strategies of Exponential Moving Averages, Relative Strength Index (RSI), Moving Average Convergence / Divergence (MACD) and Bollinger Bands® were tested on the, EUR/USD, EUR/ZAR, AUD/CAD, GBP/JPY, NZD/CHF, USD/BRL currency pairs from 1999 to 2023, and various Neural Network configurations were considered.

The results indicate that neural networks can reproduce relatively well the optimal strategy to adopt in the currency pairs analyzed. Average accuracy rates of 82% were obtained. The research contributes to the literature on financial forecasting and algorithmic trading, demonstrating the potential of neural networks as a tool for Forex trading. The dissertation concludes that, despite current limitations, neural networks have significant potential for application in Forex trading strategies but require continuous improvement.

Keywords: Forex, Neural Network, Technical Analysis, RSI, MACD, Bollinger Bands®.

Índice

Originalidade e Direitos de Autor	iii
Agradecimentos	iv
Resumo	v
Abstract	vi
Lista de Figuras	viii
Lista de Tabelas	ix
Lista de siglas e acrónimos.....	x
1. Introdução	1
2. Enquadramento Teórico	5
2.1. <i>Foreign Exchange Market</i>	5
2.2. Análise Fundamental e Análise Técnica	9
2.3. Redes Neurais Artificiais	26
3. Estudo Empírico	33
3.1. Dados e metodologia.....	33
3.2. Resultados	42
4. Conclusão	57
Referências Bibliográficas	59

Lista de Figuras

Figura 1 - Horário do Mercado <i>Forex</i> . Fonte: CMC Markets.....	8
Figura 2 - Gráfico de velas do par USD/JPY Fonte: Investing.com	11
Figura 3 - Gráfico de linhas EUR/GBP Fonte: Investing.com	12
Figura 4 - Gráfico de barras do par EUR/CHF Fonte: Investing.com.....	12
Figura 5 - Exemplo Média Móvel Exponencial no par EUR/USD (linha amarela) Fonte: CMC Markets	15
Figura 6 - Exemplo RSI no par USD/CAD Fonte: Investing.com	16
Figura 7 - Exemplo MACD no par AUD/NZD Fonte: Investing.com.....	18
Figura 8 - Exemplo <i>Bollinger Bands</i> ® no par USD/CHF Fonte: Investing.com.....	19
Figura 9 - EUR/USD mensal.....	22
Figura 10 - Standard & Poor's 1964 – 1982.....	23
Figura 11 - Standard & Poor's 1982 - 2000.....	23
Figura 12 - Caminho Rede Neuronal Artificial Fonte: Autor	27
Figura 13 - Três modelos: <i>Underfitting</i> (linha laranja). <i>Good fit</i> (linha preta). <i>Overfitting</i> (linha verde).....	29
Figura 14 - EUR/USD cotação diária (1999 a 2023) Dados: Investing.com.....	34
Figura 15 - GBP/JPY cotação diária (1999 a 2023) Dados: Investing.com	34
Figura 16 - AUD/CAD cotação diária (1999 a 2023) Dados: Investing.com.....	35
Figura 17 - NZD/CHF cotação diária (1999 a 2023) Dados: Investing.com.....	35
Figura 18 - EUR/ZAR cotação diária (1999 a 2023) Dados: Investing.com.....	36
Figura 19 - USD/BRL cotação diária (1999 a 2023) Dados: Investing.com.....	36
Figura 20 - 1 unidade de camada oculta, com um máximo de iterações de 50	40
Figura 21 - 1 unidade de camada oculta, com um máximo de iterações de 100	40
Figura 22 - Tipo de treino	41
Figura 23 - Precisão da velocidade dos indicadores.....	53
Figura 24 - Precisão por par cambial	54

Lista de Tabelas

Tabela 1 - Volume de transações Forex OTC por instrumento.	6
Tabela 2 - Volume de transações Forex OTC por moeda.....	6
Tabela 3 - Volume de transações Forex OTC por par cambial.....	7
Tabela 4 - Categorias.....	37
Tabela 5 - Inputs gerados na rede.....	37
Tabela 6 - N° de Reversões.....	38
Tabela 7 - Decisão Ótima por Par Cambial.....	38
Tabela 8 - Resumo dos resultados com 1 camada oculta com um intervalo entre 1 a 50 iterações por velocidade de indicador.....	42
Tabela 9 - Resumo dos resultados com 1 camada oculta com um intervalo entre 1 a 100 iterações por velocidade de indicador.....	43
Tabela 10 - Resumo dos resultados com 2 camadas ocultas por velocidade de indicador.....	43
Tabela 11 - Resumo dos resultados com 1 camada oculta com um intervalo entre 1 a 50 iterações por velocidade de indicador para posições Comprar.....	45
Tabela 12 - Resumo dos resultados com 1 camada oculta com um intervalo entre 1 a 50 iterações por velocidade de indicador para posições Manter.....	45
Tabela 13 - Resumo dos resultados com 1 camada oculta com um intervalo entre 1 a 50 iterações por velocidade de indicador para posições Vender.....	46
Tabela 14 - Resumo dos resultados com 1 camada oculta com um intervalo entre 1 a 100 iterações por velocidade de indicador para posições Comprar.....	47
Tabela 15 - Resumo dos resultados com 1 camada oculta com um intervalo entre 1 a 100 iterações por velocidade de indicador para posições Manter.....	48
Tabela 16 - Resumo dos resultados com 1 camada oculta com um intervalo entre 1 a 100 iterações por velocidade de indicador para posições Vender.....	48
Tabela 17 - Resumo dos resultados com 2 camadas por velocidade de indicador para posições Comprar.....	50
Tabela 18 - Resumo dos resultados com 2 camadas por velocidade de indicador para posições Manter.....	50
Tabela 19 - Resumo dos resultados com 2 camadas por velocidade de indicador para posições Vender.....	51
Tabela 20 - Resultados Individual dos Indicadores por Pares Cambiais (Treino).....	55
Tabela 21 - Resultados Individual dos Indicadores por Pares Cambiais (Teste).....	55

Lista de siglas e acrónimos

AUD/CAD	Dólar Australiano / Dólar Canadano
AUD/NZD	Dólar Australiano / Dólar Neozelandês
CNN	Neuronais Convolucionais
C-RNN	Redes Neuronais Convolucionais e Recorrentes
DJIA	<i>Dow Jones Industrial Average</i>
<i>DJTA</i>	<i>Dow Jones Transportation Average</i>
EUA	Estado Unidos da América
EUR/USD	Euro / Dólar Americano
EUR/ZAR	Euro / Rand Sul Africano
FOREX	Mercado Cambial
GBP/JPY	Libra Britânica / Iene Japonês
GBP/USD	Libra Britânica / Dolar Americano
GRU	<i>Gated Recurrent Units</i>
LSTM	Memória de Curto Prazo Longa
MACD	Convergência / Divergência da Média Móvel
MM	Média Móvel
MMA	Média Móvel Autorregressiva
MME	Média Móvel Exponencial
MMS	Média Móvel Simples
MLP	Perceptron Multicamada
NZD/CHF	Dólar Neozelandês / Franco Suíço
OTC	Sobre o Balcão (<i>Over-the-counter</i>)
PIB	Produto Interno Bruto
PSO	Otimização por Enxame de Partículas
RNA	Redes Neuronais Artificiais
RNN	Redes Neuronais Recorrentes
RS	Força Relativa
RSI	Índice de Força Relativa
SPSS	Pacote Estatístico para as Ciências Sociais
USD/IDR	Dólar Americano / Rupia Indonésia

USD/BRL	Dólar Americano / Real Brasileiro
USD/ZAR	Dólar Americano / Rand Sul Africano
VAR	Vídeo Árbitro

1. Introdução

O mercado *Foreign Trade Exchange*, mais conhecido por *Forex* ou *FOREX*, é o mercado financeiro mais dinâmico e líquido do mundo, com o maior volume de transações diárias, atraindo a atenção de *traders*, investidores e acadêmicos devido à sua volatilidade e à diversidade de pares cambiais. Este mercado está aberto durante cinco dias por semana e permite aos investidores / *traders* negociações 24 horas por dia, devido aos diferentes fusos horários em que os pares cambiais são negociados globalmente.

Este dinamismo, no entanto, traz desafios significativos na previsão de preços e na tomada de decisões. Historicamente, indicadores técnicos, como o *Relative Strength Index* (RSI), *Moving Average Convergence / Divergence* (MACD), Média Móvel Exponencial (MME) e *Bollinger Bands*® (Bandas de Bollinger) têm sido amplamente utilizados como ferramentas úteis na análise de tendências e na identificação de oportunidades de compra e venda. Contudo, o crescente avanço das tecnologias de *machine learning*, em particular das Redes Neurais Artificiais (RNAs), abriu novas possibilidades para melhorar a precisão preditiva e otimizar estratégias de investimento.

Este estudo pretende, assim, avaliar a capacidade preditiva de indicadores técnicos combinados com Redes Neurais na tomada de decisões ótimas de compra, manutenção ou venda, analisar o desempenho de diferentes categorias de pares cambiais (principais, menores e emergentes) e a sua relação com as configurações dos indicadores técnicos.

A estratégia mais simples de investimento nos mercados financeiros é a estratégia de *Buy-and-Hold*, que consiste na compra de ativos com o objetivo de os manter a longo prazo, ignorando as flutuações de curto prazo (Nanda e Peters, 2006). Vários estudos analisaram a eficácia desta estratégia em comparação com outras abordagens de investimento, como Patel (2023), onde se revelou que estratégias baseadas em Médias Móveis Simples (MMS), MACD e *Bollinger Bands*®, superam, a abordagem *Buy-and-Hold*. Assim, a procura de estratégias mais rentáveis do que a simples *Buy-and-Hold* tem sido um tema de interesse nos mercados financeiros (Patel, 2023) (Chung *et al.*, 2021). O desafio fundamental associado à estratégia *Buy-and-Hold* reside no facto de que muitas vezes o momento de entrada e saída (compra e venda, respetivamente) ser negligenciado. Isto ocorre porque o objetivo do investidor é manter essa posição aberta ao longo de vários anos, ignorando as flutuações do

mercado. Contudo, o mercado move-se por tendências e ciclos, que podem ser de alta, baixa ou de lateralização. A lateralização caracteriza-se pela baixa volatilidade dos preços, pela ausência de uma tendência clara de alta ou baixa, e por um equilíbrio temporário entre compradores e vendedores, geralmente oscilando dentro de uma zona definida por níveis de suporte e resistência (Murphy, 1999). Nesse contexto, a análise técnica pode ser uma ferramenta útil para enfrentar o desafio da entrada e saída no mercado.

A análise técnica, fundamental nos mercados financeiros, tem atraído considerável interesse e investigação na área das finanças. O RSI, MACD, *Bollinger Bands*® e as Médias Móveis (MM) têm-se destacado como ferramentas essenciais e rentáveis para os investidores (Patel, 2023). Stanković *et al.* (2015) conclui, inclusive, que o uso desses indicadores em mercados emergentes tem poder de previsão, permitindo obter rendibilidades anormais. A utilização desses indicadores não fornece apenas percepções sobre a dinâmica do mercado, mas desempenha também um papel significativo nas decisões de investimento e nas políticas económicas de determinado país. Os movimentos de preços e as tendências identificadas por meio dessas estratégias não só influenciam as decisões individuais de compra e venda de ativos, mas também podem impactar na estabilidade económica e financeira de uma nação como um todo. Um exemplo marcante foi o Acordo de Plaza, em 1985, quando o dólar americano tinha valorizado 44% em relação às principais moedas num período de cinco anos, entre 1980 e 1985 (Frankel, 2015). O objetivo do acordo, era promover uma desvalorização controlada do dólar para corrigir desequilíbrios comerciais globais. Dentro de dois anos, o valor do dólar caiu 46% em relação ao marco alemão e 50% em relação ao iene japonês (Lien, 2008).

As Redes Neurais têm tido uma aplicação crescente nos mercados financeiros, muito fruto da rápida evolução na computação. As Redes Neurais são um subconjunto de *machine learning* e constituem a base fundamental para os algoritmos de *deep learning*, desempenhando um papel fundamental na sua execução. Inspiradas pelo cérebro humano, estas redes imitam o processo dos neurónios biológicos que enviam sinais uns aos outros, oferecendo a capacidade de adaptação e aprendizagem contínua (Dastres & Soori, 2021). As Redes Neurais têm suscitado grande interesse como uma abordagem promissora para aprimorar a eficácia das estratégias aplicadas aos mercados financeiros. Nomeadamente, na exploração do seu potencial para, através da melhoria do seu poder de previsão, permitir a obtenção de rendibilidades superiores às obtidas pelas estratégias mais tradicionais, como é o caso da *Buy-and-Hold*.

Unindo a análise técnica com as análises através de Redes Neurais é possível uma compreensão mais profunda e detalhada do mercado, o que em contrapartida produz melhores resultados. Alguns estudos comprovam esta mesma ideia. Ryll e Seidens (2019) concluíram que os algoritmos de *machine-learning* superam a maioria dos métodos estocásticos na previsão dos mercados financeiros. Berradi *et al.* (2020) indicaram que as técnicas de *deep learning* no mercado financeiro das ações, índices, matérias-primas e *Forex*, podem auxiliar os investidores a tomarem decisões mais precisas.

Como tal, o estudo contínuo e aprimoramento dessas estratégias são de interesse não apenas para os participantes do mercado, mas também para os economistas, analistas financeiros, formuladores de políticas e acadêmicos que procuram entender e prever o comportamento dos mercados financeiros e a sua interação com a economia como um todo.

Esta dissertação tem como objetivo investigar e avaliar diferentes estratégias de análise técnica utilizadas no mercado *Forex*, analisando a sua eficácia, vantagens, desvantagens e implementações práticas, tendo por base a aplicação de Redes Neurais. Esta investigação visa enriquecer o conhecimento existente nos mercados financeiros e aumentar o conhecimento na área. O desafio na aplicação de qualquer estratégia efetuada nos mercados financeiros está na identificação precisa dos pontos de entrada e saída, bem como na gestão de riscos. A escolha deste tema justifica-se pela dificuldade da previsão de séries temporais do mercado cambial e pela existência de diversos estudos que aplicam as Redes Neurais em mercados acionistas.

Um contributo desta dissertação baseia-se na aplicação de Redes Neurais ao mercado *Forex*, com o objetivo de prever as entradas e saídas dos pares principais (EUR/USD – Euro / Dólar Americano, GBP/JPY – Libra Britânica / Iene Japonês), dos pares menores (AUD/CAD – Dólar Australiano / Dólar Canadiano, NZD/CHF – Dólar Neozelandês / Franco Suíço) e dos pares emergentes (EUR/ZAR – Euro / Rand Sul Africano, USD/BRL – Dólar Americano / Real Brasileiro), ao longo do período compreendido entre janeiro de 1999 e dezembro de 2023, utilizando dados históricos e indicadores técnicos na criação do modelo de previsão.

Esta dissertação encontra-se dividida em três capítulos: Enquadramento Teórico, Estudo Empírico e Conclusão. O Enquadramento Teórico inclui os principais conceitos das análises de investimento e a utilização de Redes Neurais para alcançar o objetivo proposto nesta dissertação. O capítulo Estudo Empírico aborda a metodologia adotada, detalha os dados

utilizados na pesquisa realizada, e contém a apresentação dos resultados e a análise dos mesmos. Por fim, a Conclusão aborda uma breve discussão da pesquisa efetuada, assim como, sugestões para investigações futuras.

2. Enquadramento Teórico

A crescente complexidade e volatilidade dos mercados financeiros tem impulsionado a procura por técnicas avançadas de análise e previsão. Neste contexto, as Redes Neurais emergem como uma ferramenta particularmente promissora, oferecendo capacidades de aprendizagem e adaptação que superam as limitações dos métodos tradicionais de análise técnica e fundamental. A presente dissertação foca-se na aplicação destas Redes Neurais à análise técnica no mercado *Forex*, pretendendo avaliar a eficácia de diferentes indicadores técnicos quando integrados com sistemas de *machine learning*. Esta abordagem combina a objetividade dos indicadores técnicos com a capacidade das Redes Neurais de identificar padrões complexos e não-lineares, potencialmente melhorando a precisão das previsões de movimentos de preços e, conseqüentemente, a eficácia das estratégias de investimento.

2.1. *Foreign Exchange Market*

O *Foreign Exchange Market* (*Forex* ou *FOREX*) é o mercado onde as moedas são compradas e vendidas aos intervenientes do mercado. Ao contrário dos mercados de ações tradicionais, o mercado cambial funciona de forma descentralizada, com negociações realizadas eletronicamente em mercados *Over-The-Counter* (OTC). As novas plataformas eletrónicas de negociação simplificaram o processamento de transações, reduziram riscos operacionais e custos, permitindo o surgimento de pequenos operadores e estratégias, como a negociação de alta frequência. Isto aumentou o volume de transações de *Forex* e atraiu diversos participantes (King *et al.*, 2011).

De acordo com o último inquérito do *Bank of International Settlements* (2022), são transacionados em média 7,5 triliões de dólares numa sessão diária, conforme apresentado na Tabela 1 (Bank of International Settlements, 2022). O Dólar Americano representa 88% desse volume, aproximadamente 6,6 triliões de dólares, seguido pelo Euro e pelo Iene Japonês, com 30% e 16% respetivamente (Tabela 2). No que diz respeito aos pares cambiais negociados, os cinco mais negociados são o Dólar Americano contra o Euro (22,7%), Iene Japonês (13,5%), Libra Esterlina (9,5%), Yuan Chinês (6,6%), e Dólar Canadiano (5,5%), como se verifica na Tabela 1. Os pares cambiais são caracterizados por serem ruidosos, não-estacionários e caóticos (Deboeck, 1994; Kamruzzaman & Sarker, 2003).

Tabela 1 -Volume de transações Forex OTC por instrumento.

Volume de negócios do mercado de balcão em divisas por instrumento					
Base "Net-net", médias diárias em abril em milhares de milhões de dólares americanos					
Instrumentos	2010	2013	2016	2019	2022
Instrumentos cambiais	3,973	5,357	5,066	6,581	7,508
Transacções à vista	1,489	2,047	1,652	1,979	2,107
Fowards a prazo	475	679	700	998	1,163
Swaps de divisas estrangeiras	1,759	2,24	2,378	3,198	3,81
Swaps de divisas	43	54	82	108	124
Opções e outros produtos	207	337	254	298	304
Memo:					
Volume de negócios às taxas de câmbio de abril de 2022	3,542	4,727	4,851	6,446	7,508
Derivados negociados em bolsa	144	145	115	127	152

Fonte: *Bank for International Settlements, 2022***Tabela 2 - Volume de transações Forex OTC por moeda.****Volume de negócios do mercado de balcão em divisas por moeda**

Base "Net-net", médias diárias em abril em milhares de milhões de dólares americanos e percentagem

Moeda	Volume de negócios do mercado de balcão									
	2010		2013		2016		2019		2022	
	Quant.	%	Quant.	%	Quant.	%	Quant.	%	Quant.	%
USD	3,371	84.9	4,662	87.0	4,437	87.6	5,811	88.3	6,641	88.5
EUR	1,551	39.0	1,79	33.4	1,59	31.4	2,126	32.3	2,293	30.5
JPY	754	19.0	1,235	23.0	1,096	21.6	1,108	16.8	1,253	16.7
GBP	512	12.9	633	11.8	469	12.8	843	12.8	969	12.9
CNY	34	0.9	120	2.2	202	4.0	285	4.3	526	7.0

Fonte: *Bank for International Settlements, 2022*

Tabela 3 - Volume de transações *Forex* OTC por par cambial.**Volume de negócios no mercado de balcão em divisas por par de moedas**

Base “Net-net”, médias diárias em abril em milhares de milhões de dólares americanos e percentagem

Par Cambial	Volume de negócios do mercado de balcão									
	2010		2013		2016		2019		2022	
	Quant.	%	Quant.	%	Quant.	%	Quant.	%	Quant.	%
USD/EUR	1,099	27.7	1,292	24.1	1,172	23.1	1,581	24.0	1,706	22.7
USD/JPY	567	14.3	980	18.3	901	17.8	871	13.2	1,014	13.5
USD/GBP	360	9.1	473	8.8	470	9.3	630	9.6	714	9.5
USD/CNY	31	0.8	113	2.1	192	3.8	270	4.1	495	6.6
USD/CAD	182	4.6	200	3.7	218	4.3	287	4.4	410	5.5

Fonte: Bank for International Settlements, 2022

Evolução e Características do Mercado *Forex*

A atração do mercado *Forex* reside na sua acessibilidade e personalização. Com operações disponíveis 24 horas por dia, cinco dias por semana, devido às transações que ocorrem em diferentes fusos horários, como por exemplo, através dos grandes centros financeiros como Londres, Nova Iorque, Sydney e Tóquio, os *traders* podem reagir instantaneamente a eventos globais, ao contrário dos mercados de ações com horários de negociação limitados. Podemos analisar na Figura 1 que algumas dessas sessões sobrepõem-se em determinados momentos, contribuindo para o aumento da liquidez e proporcionando potencialmente mais oportunidades de negociação, sendo que a sobreposição Londres-Nova Iorque, é conhecida pela elevada liquidez e volatilidade (King *et al.*, 2011).

Eventos Históricos e Impactos no Mercado *Forex*

No cenário histórico, eventos como o Acordo de Bretton Woods, assinado em 1944, foi um marco importante no estabelecimento de um sistema monetário internacional pós-Segunda Guerra Mundial. Este acordo estabeleceu o dólar dos Estados Unidos como a principal moeda de reserva internacional, vinculando o seu valor ao ouro. No entanto, em 1971, o presidente dos Estados Unidos da América (EUA), Richard Nixon, encerrou unilateralmente a convertibilidade do dólar em ouro, pondo fim ao sistema de Bretton Woods e inaugurando uma era de taxas de câmbio flutuantes (Lien, 2008). O acordo de Plaza, em 1985, foi uma resposta coordenada entre os países do G5 (Estados Unidos, Japão, Alemanha Ocidental, França e Reino Unido) para desvalorizar o dólar americano em relação ao iene japonês e ao marco alemão. Isso foi feito para corrigir os desequilíbrios comerciais e promover o crescimento económico global (Lien, 2008). A especulação de George Soros contra a libra esterlina, em 1992, que ganhou notoriedade em '*The Man Who Broke the Bank of England*', demonstrou a capacidade dos indivíduos influenciarem as taxas de câmbio e a volatilidade do mercado *Forex* (Lien, 2008). Estes são alguns exemplos de eventos que demonstraram a interconexão dos mercados globais e a sua influência sobre as moedas.

O lançamento do euro, em 1999, representou um ponto de viragem, introduzindo uma moeda comum para vários países da União Europeia. Embora inicialmente enfrentasse desafios, o euro agora desfruta de uma posição forte no mercado internacional de moedas (Lane, 2006). Estas ocorrências destacam a evolução do mercado *Forex*, bem como as decisões políticas e económicas dos principais países que influenciam diretamente as taxas de câmbio e a dinâmica do mercado.

2.2. Análise Fundamental e Análise Técnica

A análise de ativos financeiros pode ser abordada sob duas perspetivas principais: análise fundamental e análise técnica. A análise técnica, também conhecida como análise interna ou de mercado, foca-se na observação direta dos movimentos do mercado, procurando avaliar a oferta e a procura de títulos com base em padrões históricos e comportamento dos preços (Vuković *et al.*, 2012).

A análise técnica, tem por base a “lei” da procura e oferta, ou seja, o preço é determinado pelo equilíbrio entre a quantidade procurada e a quantidade oferecida, sendo este equilíbrio frequentemente influenciado por fatores racionais e irracionais (Kumar e Mohapatra, 2015).

No caso do mercado financeiro, esse equilíbrio é percebido através de diferentes tipos de gráficos como gráficos de vela, de linha, ou de barras como demonstra a Figura 2, Figura 3 e Figura 4. Através desses gráficos, os investidores podem identificar padrões e tendências no preço, possibilitando assim a identificação de possíveis movimentos futuros no seu valor.

No contexto específico do mercado *Forex*, a análise técnica assume uma importância particular devido à elevada liquidez e volatilidade que caracterizam este mercado. Estudos como o de Neely *et al.* (2009) demonstraram que estratégias de negociação baseadas nesta abordagem conseguem gerar retornos consistentes em mercados cambiais, validando a sua eficácia como ferramenta de apoio à tomada de decisão.

Por outro lado, a análise fundamental envolve a avaliação de fatores macroeconômicos como as taxas de juro, inflação, crescimento do PIB (Produto Interno Bruto) e balança comercial que podem influenciar a oferta e a procura de uma moeda. Andersen *et al.*, (2003) analisaram a reação do mercado *Forex* à publicação de dados da inflação e do PIB, e concluíram que estes dados afetam a volatilidade das taxas de câmbio. Clarida *et al.* (2000) demonstraram que as políticas monetárias e as mudanças de taxas de juro têm impacto significativo nas taxas de câmbio.

Engel e West (2005) aprofundaram a análise da relação entre os fundamentos macroeconômicos e as taxas de câmbio, propondo um modelo que esclarece porque é que estas aparentam seguir um percurso aleatório, apesar de estarem sujeitas à influência de variáveis fundamentais. Os autores defendem que os modelos tradicionais de valor presente, que determinam as taxas de câmbio com base nas expectativas relativas aos fundamentos futuros, podem levar a um comportamento semelhante a um passeio aleatório quando o fator de desconto se aproxima de um.

Por sua vez, Chen e Tsang (2013) exploraram o impacto da estrutura a prazo das taxas de juro na previsão das taxas de câmbio. Os autores demonstraram que os diferentes componentes dessa estrutura fornecem informações valiosas sobre as expectativas de inflação, o nível de atividade econômica e os prémios de risco, influenciando, assim, o comportamento futuro das taxas de câmbio. Esta abordagem representa um avanço face à análise fundamental tradicional, ao integrar as expectativas do mercado refletidas na estrutura das taxas de juro.

A balança comercial desempenha um papel relevante na determinação das taxas de câmbio. Quando a balança apresenta um fluxo positivo, o país em questão encontra-se a exportar mais do que a importar, o que significa que obtém um *superavit*. Esse cenário leva a um aumento da procura pela moeda nacional devido ao crescimento das exportações, o que, por sua vez, contribui para a valorização dessa moeda (Lien, 2008).

O mercado *Forex* é fortemente influenciado por variáveis macroeconómicas como taxas de juros, inflação, balança comercial e crescimento económico. Estudos empíricos demonstram que anúncios de políticas monetárias e dados económicos têm impacto significativo na volatilidade e direção das taxas de câmbio (Evans & Lyons, 2008), fatores, que sistemas baseados em Redes Neurais, podem potencialmente incorporar nas suas previsões.

Published on Investing.com, 27/Nov/2024 - 17:28:08 GMT, Powered by TradingView.
USD/JPY, Forexemtemporeal:USD/JPY, W



Figura 2 - Gráfico de velas do par USD/JPY
Fonte: Investing.com

Published on Investing.com, 27/Nov/2024 - 17:04:12 GMT, Powered by TradingView.
EUR/GBP, Forexemtemporeal:EUR/GBP, W



Figura 3 - Gráfico de linhas EUR/GBP
Fonte: Investing.com

Published on Investing.com, 27/Nov/2024 - 17:21:23 GMT, Powered by TradingView.
EUR/CHF, Forexemtemporeal:EUR/CHF, M



Figura 4 - Gráfico de barras do par EUR/CHF
Fonte: Investing.com

Segundo Silva e Nunes (2020), Charles Henry Dow, jornalista americano, é amplamente reconhecido como o pioneiro da análise técnica. Dow cofundou a *Dow Jones & Company* e teve um papel fundamental na criação do índice *Dow Jones Industrial Average* (DJIA), em conjunto com Edward Jones, estatístico, jornalista e parceiro de Dow. Embora a intenção inicial de Dow não tenha sido a previsão do preço das ações, a sua contribuição tem sido o pilar da análise técnica moderna, fornecendo valiosas informações para investidores e *traders* na avaliação e compreensão do comportamento do mercado, bem como na tomada de decisões de investimentos.

A Teoria de Dow estabelece uma estrutura conceptual abrangente para entender os movimentos do mercado financeiro. Os seis princípios da teoria de Dow, conforme Murphy (1999), são os seguintes:

- Princípio 1: O mercado reflete todas as informações disponíveis, o que implica que os preços são reflexos das expectativas e crenças coletivas dos participantes do mercado, incluindo notícias, dados fundamentais e económicos e sentimentos do mercado.
- Princípio 2: Os movimentos de preços são categorizados em três tendências principais: primária, secundária e terciária. A tendência primária é a direção de longo prazo do mercado, com duração superior a um ano e com tendências predominantes de alta ou baixa. As tendências secundárias são correções ou interrupções temporárias na tendência primária, com uma duração que varia entre três semanas a vários meses. Por fim, as tendências terciárias são movimentos de curto prazo, geralmente não excedendo três semanas. Embora as tendências terciárias possam ser úteis para os *day traders*, elas são consideradas menos relevantes no contexto da Teoria de Dow, pois representam o ruído de mercado - variações que não alteram o curso das tendências primária ou secundária.
- Princípio 3: A tendência primária é dividida em três fases distintas: acumulação, participação pública e distribuição. Na fase de acumulação, o *smart money*, representado por instituições bem informadas, inicia a compra ou venda antes da maioria dos outros participantes do mercado, aproveitando a sua vantagem informativa. Conforme a tendência se desenvolve, a participação pública aumenta, refletida por um aumento no volume de negociação, indicando a participação de investidores menos informados. Finalmente, na fase de distribuição, o *smart money* começa a fechar as posições, assinalando o fim da tendência.
- Princípio 4: Confirmação mútua entre índices, como o DJIA e o *Dow Jones Transportation Average* (DJTA), para validar uma tendência.
- Princípio 5: O volume de negociação desempenha um papel vital na confirmação da força de uma tendência, um aumento no volume indica um interesse renovado dos participantes do mercado.
- Princípio 6: Uma tendência continua válida até que ocorra uma reversão clara e definitiva, geralmente confirmada por movimentos nos índices que vão contra a tendência atual.

Contudo, Achelis (2013) defende no seu livro que o impacto de Charles Dow na análise técnica não pode ser exagerado. Dow destacou a importância dos princípios fundamentais do movimento dos preços, como a identificação de tendências (alta, baixa ou lateral) e o papel dos volumes de negociação, que se tornaram a base da análise dos mercados financeiros. Essas ideias inovadoras criaram um novo paradigma, permitindo aos investidores identificarem padrões técnicos e prever os movimentos de preço das ações com base no comportamento histórico dos preços, em detrimento de depender exclusivamente de fatores fundamentais, como a divulgação de resultados financeiros.

Indicadores Técnicos

O uso de indicadores técnicos é algo bastante comum entre os participantes do mercado financeiro, incluindo *traders* individuais, gestores de fundos e instituições financeiras, sendo também objeto de estudo frequente no meio acadêmico. Este estudo tem o objetivo de compreender a sua eficácia na previsão de movimentos de preços, uma vez que esses indicadores oferecem informações essenciais sobre a dinâmica do mercado e o movimento dos preços, ajudando os investidores a tomar decisões de investimento mais informadas.

No mercado *Forex*, os indicadores técnicos assumem particular relevância devido à sua natureza altamente líquida. Neely e Weller (2011) demonstraram que, ao contrário de outros mercados financeiros, o *Forex* exibe persistência em padrões técnicos, o que possibilita a sua exploração por parte dos *traders* através da aplicação de indicadores adequados.

De todos os indicadores existentes, as MM são, possivelmente, os mais utilizados por profissionais e analistas. É um indicador utilizado para suavizar os dados dos preços através do cálculo de um preço médio durante um período específico. Auxilia a identificar tendências e níveis de suporte (o nível de preço onde os compradores pressionam os vendedores, impedindo que o preço caia ainda mais) (Figura 5 – círculo verde), e resistência (é o nível onde a pressão vendedora excede a compradora, limitando assim a subida do preço, representando o máximo que os compradores estão dispostos a pagar) (Figura 5 – círculo vermelho). Os três tipos de MM mais utilizados são a simples (ou aritmética), a exponencial e a ponderada.



Figura 5 - Exemplo Média Móvel Exponencial no par EUR/USD (linha amarela)
Fonte: CMC Markets

O cálculo da MME é feito através da diferença do preço de fecho e a MME do dia anterior. Em seguida, esta diferença é multiplicada por um multiplicador ponderado (onde n representa o número de dias), sendo ao resultado adicionado a MME do dia anterior.

$$MME_t = (\text{Preço de Fecho}_t - MME_{t-1}) \times \left(\frac{2}{n+1}\right) + MME_{t-1}$$

Menkhoff e Taylor (2007) demonstraram que estratégias baseadas em MM podem gerar retornos significativos, especialmente em pares cambiais caracterizados por maior volatilidade. Corroborando esta perspectiva, Neely *et al.* (2009) evidenciaram que os sinais de negociação baseados em MM no mercado cambial frequentemente superaram as estratégias de *Buy-And-Hold* em diversos horizontes temporais. Os resultados obtidos por Neely *et al.* (2009) desafiam a noção de eficiência fraca do mercado de Fama (1970), uma vez que demonstram como determinadas regras técnicas, especialmente as baseadas em MM e MMA (Média Móvel Autorregressiva), conseguem prever movimentos de preços com potencial lucrativo. Esta capacidade preditiva persiste mesmo após a consideração dos custos de transação, reforçando a conclusão de que a negociação técnica mantém a sua rentabilidade em contradição às expectativas teóricas de mercados eficientes.

Um outro indicador bastante utilizado é o RSI. O RSI é um oscilador técnico desenvolvido por J. Welles Wilder em 1978. No seu livro “*New Concepts in Technical Trading Systems*” publicado em 1978, Wilder introduziu o RSI e explicou o seu cálculo e interpretação. É um oscilador de *momentum* que mede a velocidade e a mudança dos movimentos de preços, comparando ganhos e perdas recentes durante um período específico. O RSI varia entre 0 e

100, e geralmente valores acima de 70 indicam uma sobrecompra (*overbought*) do título (Figura 6 - círculo vermelho), e possíveis reversões, enquanto valores abaixo dos 30 indicam sobrevenda (*oversold*) (Figura 6 – círculo verde), e possível reversão do preço. O cálculo do RSI utiliza o RS (*Relative Strength*), que é a média dos ganhos dividida pela média das perdas nos *n* períodos escolhidos, como mostra a fórmula seguinte:

$$RSI = 100 - \frac{100}{1 + RS}$$

Os *traders* muitas vezes confiam no RSI para avaliar a força de uma tendência e tomar decisões sobre os pontos de entrada e saída no mercado. Apesar de ser comum usar o padrão 30/70, alguns investidores/*traders* frequentemente adaptam e modificam o RSI para se adequar melhor às suas preferências de negociação e condições de mercado. Ajustes na duração do período padrão e a combinação do RSI com outros indicadores são abordagens comuns. Essas modificações visam resolver as limitações do RSI (como gerar sinais falsos, ou indicar condições de sobrecompra ou sobrevenda sem que haja mudanças significativas no preço) e otimizar o seu desempenho em cenários de negociação específicos.



Figura 6 - Exemplo RSI no par USD/CAD
Fonte: Investing.com

O MACD foi desenvolvido por Gerald Appel em 1979, e é um indicador de *momentum* que combina duas MME para identificar momentos de compra:

$$MACD = 12 \text{ períodos MME} - 26 \text{ períodos MME}$$

Na Figura 7 ilustra-se a sua utilização, onde a linha azul representa a MACD, que é calculada subtraindo a MME de 26 períodos (lenta) da MME de 12 períodos (rápida), refletindo a diferença entre uma Média Móvel Exponencial mais curta e outra mais longa. A linha de sinal é representada pela linha vermelha, que é uma Média Móvel Exponencial de 9 períodos da linha MACD. Um sinal de compra (posição longa) ocorre quando a linha MACD cruza acima da linha de sinal, indicando um possível comportamento *bullish*¹. Por outro lado, quando a linha MACD cruza abaixo da linha de sinal, é visto como um potencial sinal de venda, sendo visto como uma oportunidade para assumir posições *bearish*².

Além disso, como o MACD reflete a diferença entre as duas MM, os valores oscilam em torno de zero, tanto acima quanto abaixo desse nível. A área acima de zero é considerada uma zona de sobrecompra, enquanto a área abaixo de zero é vista como uma zona de sobrevenda. Um sinal forte de posição longa tende a ocorrer quando o cruzamento acontece na zona de sobrevenda, enquanto um sinal forte de posição curta geralmente ocorre quando o cruzamento se dá na zona de sobrecompra.

¹ *Bullish*: Perspetiva otimista do mercado, expectativa de subida dos preços.

² *Bearish*: Perspetiva pessimista do mercado, expectativa de descida dos preços

Published on Investing.com, 26/Nov/2024 - 14:54:12 GMT, Powered by TradingView.
AUD/NZD, Forextemporeat:AUD/NZD, W



Figura 7 - Exemplo MACD no par AUD/NZD
Fonte: Investing.com

O RSI e o MACD, no mercado *Forex*, têm apresentado resultados variáveis. Coakley *et al.* (2016), ao analisar 22 pares cambiais transacionados em relação ao dólar americano, obtiveram retornos de 6,71% para o MACD e 10,79% para o RSI, valores considerados abaixo do retorno expectável para estratégias de negociação ativa. Outros estudos, como Yazdi e Lashkari (2013) e Vajda (2014), apresentaram resultados inconclusivos, uma vez que os desempenhos diferiram significativamente entre os diversos períodos analisados e estratégias implementadas.

No entanto, no mercado de ações, estes indicadores demonstram melhor desempenho. Chong e Ng (2008) indicam que o RSI e o MACD têm potencial para melhorar os retornos de investimento, apesar de variações na eficácia ao longo do tempo. Chong *et al.* (2014) corroboram esta perspectiva, demonstrando que estratégias de negociação baseadas no MACD e RSI produzem consistentemente retornos anormais significativos em certos mercados, como o *Milan Comit General* e o *S&P/TSX Composite Index*. Embora algumas dessas estratégias resultem em retornos negativos no mercado japonês, a análise revela que essas estratégias são robustas e eficazes em diferentes momentos.

As *Bollinger Bands*®, criadas por John Bollinger na década de 80, são linhas traçadas num gráfico de preços para avaliar a volatilidade dos preços e potenciais inversões. A linha central é uma MMS, enquanto as linhas superior e inferior são calculadas através da adição e subtração dos desvios padrão respetivamente. Representam visualmente a volatilidade, com as bandas mais largas a indicarem uma maior volatilidade (Figura 8).

Bollinger (1992) indica que as *Bollinger Bands*® não fornecem sinais absolutos de compra e de venda quando os preços tocam nas bandas. Em vez disso, oferecem um contexto para avaliar os movimentos de preços em relação aos indicadores, ajudando os investidores a identificar oportunidades de negociação com base na volatilidade do mercado.

Em contraste com os indicadores anteriormente mencionados, Coakley *et al.* (2016) analisaram as *Bollinger Bands*® nos mesmos 22 pares de moedas transacionados em relação ao dólar americano e documentaram que estratégias baseadas neste indicador realizaram um retorno anual substancialmente maior, de 20,6%. Chen *et al.* (2014) corroboraram estes resultados, analisando 4 pares cambiais transacionados em relação ao dólar americano e confirmando a eficácia das *Bollinger Bands*® como ferramenta de análise técnica no mercado *Forex*.




Figura 8 - Exemplo *Bollinger Bands*® no par USD/CHF
Fonte: Investing.com

A análise técnica e a análise fundamental são métodos populares de avaliação de investimentos, amplamente utilizados no mercado cambial, cada uma com as suas vantagens e limitações. A análise técnica, foca-se em padrões e indicadores de preços e é particularmente aplicável ao mercado cambial devido à sua natureza quantitativa e à abundância de dados históricos de preços e volumes. No entanto, os sinais de entrada ou

saída podem ser falsos e a interpretação dos indicadores é subjetiva, desconsiderando o valor intrínseco das moedas. Em contrapartida, a análise fundamental oferece uma visão de longo prazo baseada em dados económicos e financeiros, mas é demorada e sujeita a incertezas devido a fatores imprevistos. Ambas as abordagens enfrentam o desafio, onde os preços dos ativos podem permanecer irracionalmente altos ou baixos por períodos prolongados. Os investidores devem reconhecer que nenhuma estratégia garante 100% de eficácia, e que o mercado pode ser imprevisível, mudando de direção independentemente das análises realizadas.

Ambas as abordagens possuem vantagens e limitações. A análise técnica, embora mais estruturada e baseada em padrões históricos, ainda depende da interpretação dos *traders* e pode ignorar fatores fundamentais relevantes. Por outro lado, a análise fundamental fornece uma visão mais abrangente sobre o valor intrínseco de um ativo, mas é frequentemente influenciada pela subjetividade nas avaliações e exige maior dedicação de tempo para a análise detalhada dos dados económicos.

No contexto do *Forex*, as Redes Neurais têm surgido como ferramentas úteis para superar algumas dessas limitações, especialmente da análise técnica. Devido à sua capacidade de identificar padrões complexos e não lineares em grandes volumes de dados, as Redes Neurais conseguem processar indicadores técnicos de maneira mais sofisticada.

Estratégias Base de Investimentos

As estratégias de investimento variam conforme os objetivos e perfis dos investidores. Três estratégias bem conhecidas, que os investidores utilizam nos mercados financeiros, são o *Buy-and-Hold*, *Momentum* e *Contrarian*. Cada uma reflete uma filosofia distinta, desde manter ativos a longo prazo (*Buy-and-Hold*) até explorar tendências de preços (*Momentum*) ou movimentos contrários ao mercado (*Contrarian*), oferecendo diferentes formas de maximizar os investimentos e gerir os respetivos riscos.

- Estratégia *Buy-and-Hold*

Esta estratégia envolve a compra de ativos financeiros com o objetivo de mantê-los a longo prazo, ignorando as flutuações de curto prazo que podem ocorrer no mercado (De Bondt e Thaler, 1985) (Jegadeesh e Titman, 1993).

Vários estudos têm examinado a eficácia da estratégia de *Buy-and-Hold* em diferentes mercados e classes de ativos. Um estudo clássico, realizado por Fama e French (1988), analisou o desempenho das ações nos Estados Unidos ao longo de várias décadas. Os escritores supracitados descobriram que as ações mantidas a longo prazo superaram as estratégias de negociação ativa em termos de retorno. Esse resultado foi corroborado por muitos outros estudos, por exemplo, o trabalho de Malkiel (1996) analisou a eficiência do mercado de ações e concluiu que a negociação ativa não é consistentemente lucrativa, em contrapartida da estratégia de *Buy-and-Hold*, que oferece retornos atrativos a longo prazo. Graham e Dodd (1934) estabeleceram as bases para a análise fundamental moderna, no seu livro “*Security Analysis*”, e argumentaram que comprar ativos a preços significativamente abaixo do seu valor intrínseco proporciona uma proteção contra erros de avaliação e volatilidade do mercado, permitindo que os investidores reduzam o risco de perdas substanciais. Além disso, Elton *et al.* (1996) revelaram que a estratégia *Buy-and-Hold* teve um desempenho superior ao de muitos fundos mútuos geridos ativamente a longo prazo. Isso sugere que os investidores, que se limitam a comprar e a manter uma carteira diversificada de ativos tendem a obter melhores rendimentos em comparação com os que negociam ativamente e tentam controlar o mercado.

No entanto, como podemos ver na Figura 9, uma estratégia de *Buy-And-Hold* no mercado *Forex* nem sempre resulta em desempenhos positivos, uma vez que o preço em 2004 é superior ao preço em 2024. O mercado cambial é altamente competitivo, especialmente no caso do EUR/USD, onde duas moedas fortes competem entre si, resultando em muitos períodos de lateralização. Como mencionado anteriormente, Neely *et al.* (2009) demonstraram que a estratégia de *Buy-And-Hold* tende a ter desempenho inferior a estratégias baseadas em análise técnica no contexto cambial. Esse comportamento contrasta com o mercado de ações, onde o *Buy-And-Hold* frequentemente supera as estratégias de *trading* ativo. Menkhoff e Taylor (2007) atribuem esta diferença às características próprias do mercado *Forex*, como a negociação contínua, a alta liquidez e a grande influência de fatores macroeconômicos sobre as taxas de câmbio.




Figura 9 - EUR/USD mensal.

Fonte: Yahoo Finance

Um exemplo ilustrativo é o período de 1964 a 1982, durante o qual o índice norte-americano *Standard & Poor's 500* passou por 18 anos de lateralização ou declínio (Figura 10). Isso significa que os investidores que investiram nesse período tiveram de aguardar vários anos apenas para recuperar o investimento inicial (*break-even*). Após esse declínio, um novo ciclo de crescimento iniciou, entre 1982 e 2000, o que significa que os investidores que entraram cedo nesse novo ciclo foram muito bem recompensados (Figura 11). No entanto, como é conhecido, esse ciclo positivo chegou bruscamente ao fim após 18 anos. Conclui-se que é possível realizar lucros com a estratégia *Buy-and-Hold*, contudo o horizonte temporal é geralmente bastante elevado, e está sujeito às oscilações do mercado e às condições económicas de determinado país.




Figura 10 - Standard & Poor's 1964 – 1982

Fonte: Macrotrends



Figura 11 - Standard & Poor's 1982 - 2000

Fonte: Macrotrends

- Estratégia de *Momentum*

Esta estratégia baseia-se na ideia de que os ativos que apresentaram um forte desempenho recentemente, continuarão nesse sentido, enquanto os ativos com desempenho fraco continuarão a ter um desempenho inferior.

Okunev e White (2003) identificaram padrões significativos de *momentum* em diversos pares cambiais, demonstrando que tais estratégias geraram retornos sustentáveis por longos períodos, mesmo considerando os custos operacionais.

Um evento marcante em relação à estratégia de *momentum* foi o caso peculiar do programa criado no início de 1980, por Richard Dennis, um *trader* de *commodities*, e o seu parceiro William Eckhardt. Tiveram um desacordo sobre se as habilidades de um *trader* profissional

podiam ser ensinadas ou se eram inatas. Dennis defendia que era possível aprender a negociar com sucesso por meio de uma abordagem sistemática, seguindo determinadas regras, enquanto Eckhardt defendia a ideia do talento inato. Para resolver esse desacordo, Dennis decidiu fazer uma experiência e colocou um anúncio no *Wall Street Journal*, do qual selecionou um grupo de indivíduos que mais tarde seriam conhecidos como os *Turtles*. Os *Turtles* eram um grupo diversificado, com pouca experiência nos mercados financeiros, mas apresentavam habilidades e ocupações que requeriam um certo nível de inteligência. Embora a experiência *Turtle Trading* seja amplamente conhecida na comunidade de *traders*, não existem muitos artigos científicos especificamente focados no sucesso ou desempenho dos *Turtles* individuais. Os participantes da experiência *Turtle* estavam vinculados por acordos de confidencialidade, limitando a disponibilidade de informações e dados detalhados para análise científica. Em Covell (2007) é investigada a história dos *Turtles* e os seus métodos de negociação, pelo que foi observado que o sistema de negociação era baseado no *trend following*, em que o sinal de entrada surgia quando a “vela japonesa” fechava num novo máximo de 55 dias (posição longa) e num novo mínimo de 55 dias (posição curta), o sinal de saída surgia quando existisse uma quebra de 20 dias na direção oposta. Essa experiência pode ser considerada um sucesso, uma vez que, no geral, os *traders* obtiveram lucros de 175 milhões de dólares em 4 anos, com uma taxa de retorno composta de 80% (Covell, 2007).

- Estratégia *Contrarian*

Na prática, esta estratégia envolve a compra de títulos que estão atualmente em desvantagem ou que sofreram quedas significativas de preços, e a venda quando estão atualmente em vantagem ou que sofreram aumentos significativos de preços. O raciocínio é que o mercado pode ter reagido de forma exagerada a notícias negativas ou positivas, conduzindo a preços incorretos que podem ser explorados para potenciais lucros. Existe uma estratégia usada por *traders* designada por *mean reversion*, em que embora o conceito esteja relacionado, apresenta características distintas. Não obstante, ambas as estratégias contrariam a tendência do mercado, a *mean reversion* centra-se no regresso do preço às MM, geralmente após períodos de bastante volatilidade e de um crescimento ou decréscimo acentuado do desempenho num curto espaço de tempo, enquanto a estratégia *contrarian* baseia-se no sentimento do mercado / investidores, e explora as reações excessivas.

Um exemplo de investimento *contrarian* é o realizado pelo famoso investidor Warren Buffet. Segundo Buffet (1986), “*we simply attempt to be fearful when others are greedy and*

to be greedy only when others are fearful”, esta frase reflete a essência da estratégia de investimento *contrarian*, pelo que destaca a importância do pensamento *contrarian* e de tirar partido das ineficiências existentes no mercado, em vez de seguir a mesma mentalidade dos restantes investidores.

Jegadeesh e Titman (1993) investigaram as estratégias de *momentum* e *contrarian* no mercado de ações dos EUA. Concluíram que as ações que tiveram um desempenho excepcionalmente positivo ou negativo nos últimos três a doze meses continuaram a apresentar um desempenho acima da média nos meses seguintes, demonstrando a existência da estratégia de *momentum*. Além disso, também observaram indícios de inversões de preços a curto prazo, indicando que as ações com fraco desempenho no passado tendiam a registar retornos positivos, enquanto as ações com forte desempenho no passado tinham a tendência a registar retornos negativos subsequentes. O estudo de De Bondt e Thaler (1985) examinou se o mercado das ações reage de forma exagerada às notícias, e encontraram evidências de inversões de preços significativas, indicando que as ações que sofreram movimentos extremos de preços tendiam a reverter para a sua média ao longo do tempo (*mean reversion*). Esse facto pôs em causa a hipótese do mercado eficiente e apoiou as estratégias de investimento *contrarian*.

A análise técnica na informação que produz é objetiva e quantificável, uma vez que se baseia em dados como preço e volume. Além disso, foca-se na psicologia do mercado, identificando mudanças de sentimento dos investidores que podem não ser óbvias apenas na observação dos dados fundamentais das empresas.

Kahneman e Tversky (1979) desafiaram a teoria tradicional da tomada de decisão racional e introduziram a teoria do prospecto (*prospect theory*), que se concentra na forma como os indivíduos avaliam os ganhos e perdas em relação a um ponto de referência. Salientaram ainda a diminuição da sensibilidade aos ganhos e perdas e discutiram os vieses que afetam a tomada de decisões.

A teoria do prospecto de Kahneman e Tversky (1979) teve um impacto significativo nas finanças comportamentais, onde podemos concluir que os investidores apresentam enviesamentos e comportamentos irregulares nos mercados financeiros, contradizendo a teoria dos mercados eficientes de Fama (1970). No entanto, ao integrar as decisões dos investidores, a análise técnica pode assumir um carácter subjetivo, dado que essas decisões são frequentemente influenciadas por vieses e perceções individuais. As Redes Neurais,

por sua vez, têm como objetivo eliminar essa subjetividade da mente humana, reduzindo o impacto do erro humano, e minimizando os erros nas decisões de investimento.

Campbell *et al.* (1997) realçaram as limitações dos modelos lineares tradicionais na captura da dinâmica dos mercados financeiros, argumentando que a complexidade e não-linearidade inerentes aos dados financeiros exigem abordagens mais flexíveis. Os autores sugeriram que modelos não-lineares, como Redes Neurais, poderiam oferecer *insights* valiosos sobre padrões nos dados financeiros que não são capturados por modelos lineares convencionais.

2.3.Redes Neurais Artificiais

O uso de Redes Neurais Artificiais (RNAs) na previsão de preços tem ganho destaque devido à sua capacidade de identificar e aprender padrões complexos em grandes volumes de dados, permitindo realizar previsões precisas com base nesses padrões. As RNAs são inspiradas no funcionamento do cérebro humano em dois aspetos principais: primeiro, pelo processo de aprendizagem que permite adquirir conhecimento de forma progressiva, e segundo, pela capacidade de armazenar o conhecimento adquirido por meio de conexões fortes entre os neurónios artificiais. As Redes Neurais utilizam uma arquitetura composta por camadas de neurónios artificiais interligados, sendo amplamente aplicadas em diversas áreas.

Uma RNA é composta por três componentes principais: a camada de entrada, que recebe os dados iniciais e o resultado dos indicadores, as camadas ocultas, que processam os dados e aplicam funções matemáticas para detetar relações complexas, e a camada de saída, que fornece o resultado final (Figura 12). O funcionamento das RNAs baseia-se em algoritmos de *machine learning* (aprendizagem automática), como o *backpropagation*, que ajusta os pesos das conexões entre os neurónios para minimizar o erro entre as previsões da rede e os valores reais. Essa abordagem permite que as RNAs aprendam a modelar comportamentos não lineares, tornando-se especialmente úteis em contextos complexos.

Uma das aplicações promissoras está nos mercados financeiros, tema central desta dissertação. A sua capacidade de modelar e analisar dados históricos de preços, volumes, e outros indicadores técnicos com o objetivo de identificar padrões complexos, torna-as valiosas para os *traders* e analistas que procuram ganhar vantagem neste ambiente altamente volátil. Neste contexto, estudos recentes demonstram que as RNAs superam métodos tradicionais em precisão e capacidade preditiva. Estudos como o de Markova (2019) destaca

o uso de RNAs para prever taxas de câmbio, como a relação entre o euro e o dólar, com um nível de precisão que supera modelos estatísticos tradicionais.




Figura 12 - Caminho Rede Neuronal Artificial
Fonte: Autor

Para um neurônio artificial, Rosenblatt (1958) representou a operação básica como:

$$y = f(\sum_i w_i N_i + b)$$

Onde y é o output (probabilidade de subida de um preço), w_i são os pesos sinápticos que determinam a importância de cada input, N_i são os inputs (por exemplo, valores dos indicadores técnicos), b é o enviesamento (*bias*) e f é a função de ativação.

Exemplo prático baseado na Figura 12:

1. Camada de entrada (três indicadores):
 - i. Preço (PR): Com valor 0.80;
 - ii. Índice de Força Relativa (RSI): Com valor 0.75;
 - iii. Média Móvel (MM): Com valor 0.70;
2. Camada oculta (quatro neurónios N_1, N_2, N_3, N_4):
 - i. Aplicando a função sigmoide $= f(\sum_i w_i N_i + b)$;
 - ii. $N_1 = f(0.5 \times 0.8 + 0.4 \times 0.75 + 0.3 \times 0.70) = f(0.91) = 0.713$;
 - iii. $N_2 = f(0.4 \times 0.8 + 0.6 \times 0.75 + 0.3 \times 0.70) = f(0.98) = 0.727$;
 - iv. $N_3 = f(0.2 \times 0.8 + 0.45 \times 0.75 + 0.6 \times 0.70) = f(0.9175) = 0.715$;
 - v. $N_4 = f(0.7 \times 0.8 + 0.4 \times 0.75 + 0.5 \times 0.70) = f(1.21) = 0.77$;
3. Camada de saída (um neurónio para estimar probabilidade de subida do preço (0-1)):
 - i. Fórmula: $P = f(w_4 \times N_1 + w_5 \times N_2 + w_6 \times N_3 + w_7 \times N_4 + b)$;
 - ii. $P = f(0.6 \times 0.713 + 0.5 \times 0.727 + 0.7 \times 0.715 + 0.4 \times 0.77) = f(1.60) = 0.832 = 83,2\%$;
 - iii. O resultado final indica que existe uma probabilidade de 83% de o preço subir.

Durante a fase de treino das Redes Neurais, existem dois desafios comuns: o sobreajuste (*overfitting*) e subajuste (*underfitting*). O *overfitting* ocorre quando um modelo é excessivamente treinado ou muito complexo, obtendo até os ruídos dos dados, enquanto o *underfitting* surge quando o treino é insuficiente ou as variáveis de entrada não são relevantes para identificar padrões claros. Ambas as situações resultam num modelo com baixa capacidade de generalização para novos dados (Figura 13) (IBM, n.d-a).




Figura 13 - Três modelos: *Underfitting* (linha laranja). *Good fit* (linha preta). *Overfitting* (linha verde).

Fonte: Medium – Jaron Collis

Para mitigar estes problemas, têm sido desenvolvidas técnicas de regularização específicas para dados financeiros. Particularmente importante é a regularização adaptativa para dados não-estacionários, uma característica intrínseca do mercado *Forex*. Os pares cambiais são caracterizados pelo seu caráter não-estacionários, com características estatísticas que mudam ao longo do tempo devido a fatores macroeconómicos e políticos.

Reforçando a importância dos indicadores técnicos, Sezer *et al.* (2017) mostraram no seu estudo que a otimização dos parâmetros dos indicadores técnicos melhora o desempenho da negociação de ações através do oscilador RSI, para a previsão de pontos de compra e venda, e a MMS para a previsão de tendências. Os resultados indicam que o modelo estudado atinge resultados comparáveis ou até melhores, quando comparados com os da estratégia *Buy-and-Hold* e outros modelos da análise técnica de diferentes ações do índice Dow Jones.

Sezer e Ozbayoglu (2018) introduzem uma nova abordagem à negociação algorítmica utilizando Redes Neurais Convolucionais (CNN) profundas. As Redes Convolucionais são amplamente utilizadas em tarefas de classificação de imagens e visão computacional, como o reconhecimento de objetos (IBM, n.d-b). As redes converteram dados financeiros em imagens em escala de cinzentos para captar padrões e tendências. Geraram um modelo CNN que superam modelos tradicionais como *Long Short-Term Memory Networks* (LSTM) (Memória de Curto Prazo Longa) (que resolvem o problema de desaparecimento dos gradientes) e *Multi-Layer-Perceptron* (MLP) (uma arquitetura de rede neural tradicional composta por camadas totalmente conectadas), bem como estratégias clássicas de investimento, incluindo *Buy-and-Hold*, RSI, e MM, destacando-se em termos de precisão e rentabilidade.

As LSTM, introduzidas por Hochreiter e Schmidhuber (1997), são uma arquitetura especializada de Redes Neurais Recorrentes (RNN) que resolve o problema do desvanecimento do gradiente através de um mecanismo de portas (*gates*) que permite à rede manter informação relevante por períodos mais longos. No contexto do mercado *Forex*, onde as dependências temporais podem estender-se por diversos horizontes temporais, esta característica é particularmente importante. As LSTM incluem três tipos de portas: a porta de esquecimento (*forget gate*), que determina qual a informação que deve ser descartada; a porta de entrada (*input gate*), que controla quais os valores que serão atualizados; e a porta de saída (*output gate*), que define qual a parte do estado da célula será transmitida como saída. Fischer e Krauss (2018) aplicaram estas redes à previsão de retornos no mercado de ações, superando abordagens tradicionais.

Uma evolução mais recente são as *Gated Recurrent Units* (GRU), propostas por Cho *et al.* (2014), que representam uma simplificação das LSTM com apenas duas portas (*reset* e *update*), resultando em menor complexidade computacional sem comprometer significativamente o desempenho. Esta característica torna-as atrativas para aplicações em tempo real no mercado *Forex*, onde a rapidez de processamento pode ser um fator crítico para a execução oportuna de estratégias de *trading*.

Num estudo recente, Nuraeni *et al.* (2020) concentraram-se na previsão dos pares cambiais USD/IDR através de Redes Neurais e do método *Particle Swarm Optimization* (PSO)³, ao longo do período de janeiro a dezembro de 2019. Os 261 registos, foram divididos em duas fases. Primeiramente, uma fase de treino com 222 registos e, de seguida, uma fase de teste com 39 registos. Através do método das Redes Neurais, foi obtida uma precisão de 90% na previsão do par cambial. No entanto, ao incorporar o PSO, a precisão aumentou para 100%. Este estudo conclui que, incorporar o método PSO, melhora a precisão das previsões no par cambial dólar americano / rupiah indonésia.

As Redes Neurais não são restritas a um único tipo de modelo, isto significa que é possível criar modelos híbridos, combinando diferentes tipos de redes simultaneamente, para melhorar a precisão das previsões. Ni *et al.* (2019) desenvolveram um modelo de previsão que integra Redes Neurais Convolucionais e Recorrentes (C-RNN), para explorar as

³ Este método de partículas tem raízes em duas metodologias de componentes principais: os seus laços com a vida artificial em geral; e com o bando de aves, o cardume de peixes e a teoria dos enxames em particular, funciona através da interação entre os dados, de forma a encontrar a solução ótima, ajustando com base nas experiências (Kennedy e Eberhart (1995)),

características espaciais e temporais dos dados *Forex*. Esta abordagem híbrida foi validada numa década de dados de nove pares de moedas importantes, mostrando uma maior precisão de previsão em comparação com os métodos tradicionais. O modelo C-RNN aborda a complexidade das séries temporais financeiras, oferecendo uma ferramenta mais eficaz para gerir a dinâmica do mercado *Forex* e informar as estratégias de negociação.

Faru *et al.* (2023) desenvolveram um modelo que integra as características das RNN que se destacam pela sua capacidade de processar dados sequenciais graças à presença de conexões recorrentes que permitem à rede reter informações de estados anteriores, e das LSTM. Essa combinação aborda as limitações de cada método individual, especialmente no tratamento de dados sequenciais. Além disso, o modelo híbrido utilizou aprendizagem por transferência, onde um modelo pré-treinado foi ajustado especificamente para determinados pares de moedas, o que aumentou significativamente a precisão das previsões. Ao comparar com modelos independentes de RNN e LSTM, o modelo híbrido mostrou-se mais eficaz na previsão de pares de moedas como GBP/USD, USD/ZAR e AUD/NZD. Esta abordagem evidencia o potencial das Redes Neurais híbridas na previsão financeira, particularmente em ambientes com dados complexos e dependentes do tempo.

Para além disso, as Redes Neurais otimizam as funções dos profissionais no setor da saúde, ao facilitar o acesso a informações, proporcionando melhores serviços aos seus utentes (Ammenwerth *et al.*, 2003). No desporto competitivo, a tecnologia VAR (*Video assistant refere* – Video árbitro), baseada em inteligência artificial, tem sido utilizada para analisar, de forma rápida, eficaz e de forma justa, lances suspeitos (Mohammed *et al.*, 2024). Em atividades físicas, dispositivos como *smartwatches* integram inteligência artificial para monitorizar padrões de saúde dos indivíduos, fornecendo diariamente análises detalhadas sobre atividades, sono e outros indicadores de saúde, diretamente no *smartphone* do utilizador (Mohammed *et al.*, 2024).

No contexto da análise técnica, as RNAs oferecem vantagens significativas. Tradicionalmente, os indicadores técnicos, como o RSI, MACD, MME e *Bollinger Bands*®, dependem de parâmetros pré-definidos, que podem não captar a complexidade dinâmica do mercado *Forex*. As Redes Neurais, por outro lado, têm a capacidade de integrar múltiplos indicadores, aprendendo automaticamente os pesos e relevância de cada um deles, dependendo do comportamento específico de cada par cambial e período analisado.

A aplicação de RNAs no mercado *Forex* é sustentada por várias razões. Em primeiro lugar, as Redes Neurais têm a capacidade de integrar dados heterogêneos, processando simultaneamente múltiplos indicadores técnicos, o preço e o volume. Em segundo lugar, a sua adaptação a mercados dinâmicos (como o *Forex*) destaca-se como uma vantagem significativa, uma vez que a aprendizagem contínua permite que as RNAs ajustem as previsões à medida que novas informações se tornam disponíveis. Por fim, uma vantagem fundamental das Redes Neurais é a sua capacidade de eliminar a subjetividade inerente ao processo de análise tradicional. Ao contrário dos analistas humanos, cujas interpretações podem ser influenciadas por vieses cognitivos e emocionais, estas redes baseiam-se exclusivamente em dados objetivos e padrões matemáticos, garantindo assim uma abordagem mais imparcial e consistente.

No caso desta dissertação, as RNAs foram aplicadas para prever as decisões de Comprar, Manter ou Vender em diferentes pares cambiais, utilizando indicadores técnicos como *inputs*. Esta abordagem permite avaliar não apenas a eficácia das redes na previsão de tendências de preços, como também automatizar a negociação. A automatização do processo de negociação representa uma vantagem significativa, uma vez que elimina atrasos na execução de ordens, remove a interferência emocional nas decisões de investimento e possibilita a operação contínua no mercado 24 horas por dia. Além disso, o sistema automatizado baseado em RNAs consegue processar e analisar simultaneamente múltiplos pares cambiais e *timeframes*, algo praticamente impossível para um *trader* humano realizar com a mesma eficiência e precisão. Esta capacidade traduz-se não só numa potencial melhoria dos resultados financeiros, mas também numa redução considerável do tempo dedicado à análise e monitorização dos mercados.

3. Estudo Empírico

Este capítulo apresenta o estudo empírico realizado para avaliar a capacidade preditiva dos indicadores técnicos no mercado *Forex*. A análise recorre a Redes Neurais para identificar padrões nos movimentos dos preços e prever as melhores decisões de investimento. Através de diferentes configurações e períodos dos indicadores técnicos, procura-se compreender quais combinações oferecem maior precisão na previsão de sinais de Compra, Manter e Venda em diversos pares cambiais, tendo em conta as suas características específicas de volatilidade e liquidez.

3.1. Dados e metodologia

O mercado *Forex* foi selecionado devido à sua dinâmica global e relevância, sendo um dos mercados financeiros mais líquidos e ativos globalmente. O objetivo desta dissertação é avaliar a capacidade preditiva dos indicadores técnicos na tomada de decisões ótimas de Comprar, Manter e Vender em diferentes pares cambiais, utilizando Redes Neurais. A escolha dos pares cambiais seguiu um critério que considerou dois pares de cada categoria (principais: EUR/USD – Euro / Dólar Americano, GBP/JPY – Libra Britânica / Iene Japonês, menores: AUD/CAD – Dólar Australiano / Dólar Canadiano, NZD/CHF – Dólar Neozelandês / Franco Suíço e emergentes: EUR/ZAR – Euro / Rand Sul Africano, USD/BRL – Dólar Americano / Real Brasileiro), com o intuito de compreender se os indicadores técnicos apresentam melhor capacidade preditiva em mercados com diferentes níveis de volatilidade, ao longo do período compreendido entre janeiro de 1999 e dezembro de 2023. Os pares analisados refletem características distintas, influenciadas por fatores económicos e políticos. Por exemplo, e como já foi referido anteriormente, o par EUR/USD, apresenta alta liquidez Tabela 3 devido ao elevado número de participantes no mercado, e às condições e eventos macroeconómicos na Europa e nos Estados Unidos da América. Em contrapartida, os pares como USD/BRL e o EUR/ZAR apresentam menos liquidez, e refletem dinâmicas regionais específicas e em regiões com maior risco. Esta abordagem foi adotada para explorar como os indicadores técnicos e as Redes Neurais se comportam em mercados com diferentes níveis de liquidez, volatilidade e relevância económica global.

Os dados foram extraídos da base de dados do site *investing.com*, e abrange um total de 39106 registos, dos 6 pares referidos. O comportamento do preço destes pares é representado

na Figura 14, Figura 15, Figura 16, Figura 17, Figura 18 e Figura 19, ao longo do período em análise. No entanto, a análise enfrentou limitações impostas pela base de dados utilizada. Embora essa cobertura temporal seja uma vantagem significativa, a ausência de dados sobre o volume de negócios impossibilitou a análise conjunta do preço dos indicadores técnicos e dos volumes transacionados. Esta limitação pode impactar a eficácia dos modelos preditivos, uma vez que o volume é frequentemente usado para confirmar tendências (Princípio 5 do Dow anteriormente referido) e validar sinais de compra e de venda. Sem essa variável, a análise baseia-se exclusivamente nos preços e nos respectivos indicadores, o que pode reduzir a capacidade dos modelos em captarem mudanças no mercado.




Figura 14 - EUR/USD cotação diária (1999 a 2023)
Dados: Investing.com

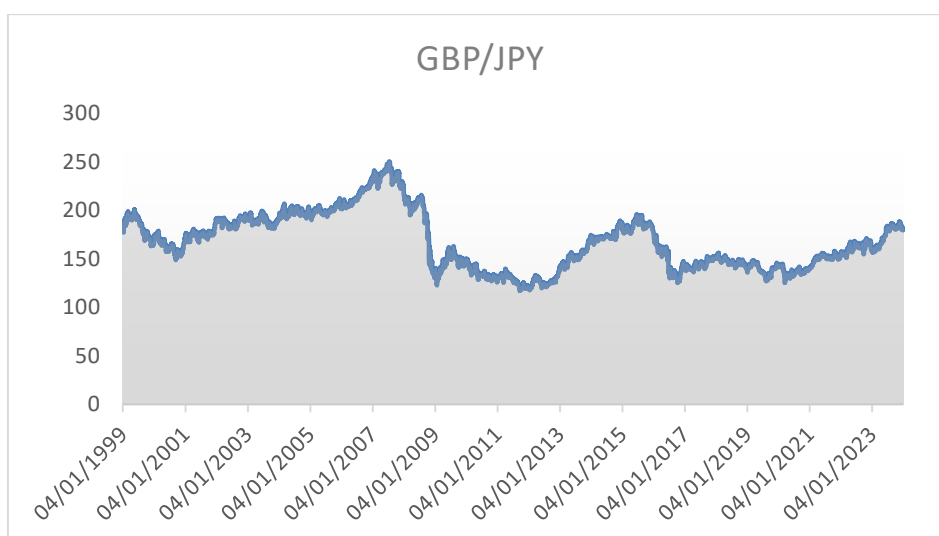


Figura 15 - GBP/JPY cotação diária (1999 a 2023)
Dados: Investing.com




Figura 16 - AUD/CAD cotação diária (1999 a 2023)
Dados: Investing.com




Figura 17 - NZD/CHF cotação diária (1999 a 2023)
Dados: Investing.com




Figura 18 - EUR/ZAR cotação diária (1999 a 2023)
Dados: Investing.com



Figura 19 - USD/BRL cotação diária (1999 a 2023)
Dados: Investing.com

Na previsão da decisão de investimento foram utilizados os indicadores técnicos RSI, MME, MACD e as *Bollinger Bands*®, apresentados e explicados no capítulo anterior. Estes indicadores foram escolhidos devido à sua ampla aplicação em diversos estudos científicos, e à sua popularidade entre os participantes do mercado. De acordo com o Saxo Bank, esses quatro indicadores estão entre os mais comuns no mercado financeiro, refletindo assim a sua relevância prática para esta dissertação. Estes indicadores foram organizados em três categorias distintas: Rápido, Padrão e Lento, tendo em conta o número de dias utilizados no seu cálculo, conforme se descreve de seguida.

A categoria Rápido inclui indicadores calculados com base em períodos de análise mais curtos, como, por exemplo, o RSI, para períodos entre 2 e 10 dias e MME com médias de

10 e 20 dias. A categoria Lento, por outro lado, utiliza valores com um maior número de dias, como o RSI para períodos entre 11 e 20 dias. A categoria Padrão considera os períodos mais frequentemente utilizados por analistas/investidores, como o RSI de 14 dias e o MACD com MME de 12 e 26 dias (Tabela 4).

A divisão dos indicadores nas categorias acima referidas, visa avaliar a sensibilidade do modelo às diferentes dinâmicas do mercado. Geralmente, os indicadores Rápido são mais eficazes para captar flutuações de curto prazo. Os indicadores Padrão oferecem um equilíbrio entre estabilidade e sensibilidade. Por outro lado, os indicadores Lento procuram identificar tendências definidas, sendo úteis em estratégias de médio a longo prazo.

Tabela 4 - Categorias

Rápido	Padrão	Lento
RSI 2 a 10 dias	RSI 14 dias	RSI 11 a 20 dias
MME 5, 10 e 20 dias	MME 50 e 100 dias	MME 150, 200 e 400 dias
MACD 5 e 20 dias	MACD 12 e 26 dias	MACD 13 e 50 dias
<i>Bollinger Bands</i> ® (média 10 dias)	<i>Bollinger Bands</i> ® (média 20 dias)	<i>Bollinger Bands</i> ® (média 100 dias)

Tabela 5 - Inputs gerados na rede

Indicador Técnico	Períodos Configurados (dias)	Número de Inputs
RSI	2 a 20	19
MME	5, 10, 20, 50, 100, 150, 200, 400	8
MACD	(5;20;8), (12;26;9), (13;50;15)	3
<i>Bollinger Bands</i>®	10, 20, 50,100	4

Note-se que, para cada análise, foram considerados apenas os períodos em que todos os indicadores tinham valores disponíveis. Esta opção é particularmente relevante para os indicadores Lento, como a MME de 400 dias.

A previsão das Redes Neurais de Comprar, Manter e Vender é comparada com a decisão ótima de Comprar, Manter e Vender que foi determinada com base num modelo de programação linear que teve como objetivo maximizar o valor do investimento no final do período em análise. Nesta otimização não foram considerados custos de transação.

Análise dos dados

Conforme evidenciado na Tabela 6, em média 54,25% das vezes, o preço sofre uma reversão em relação ao dia anterior. Isto significa que é mais provável que o preço apresente um comportamento oposto ao do dia anterior, do que continuar o *momentum*. Esta tendência de reversão sugere que os pares tendem a corrigir movimentos de curto prazo com maior frequência, o que pode ser um fator crucial na definição de estratégias de *trading*, particularmente em contextos de curto prazo onde a reversão do preço pode ser explorada.

Tabela 6 - N° de Reversões

Par	Reversões	Total	%
AUD/CAD	3414	6109	52,75%
EUR/USD	3376	6097	55,37%
EUR/ZAR	3314	6117	54,18%
GBP/JPY	3255	6085	53,49%
NZD/CHF	3275	6056	54,08%
USD/BRL	3356	6036	55,60%

Como evidenciado na Tabela 6, esta análise destaca a importância de selecionar indicadores técnicos capazes de “apanhar” movimentos rápidos e identificar padrões de reversão. Embora existam períodos de continuidade, o comportamento do mercado tende a corrigir-se rapidamente, indicando uma natureza volátil e, em muitos casos, contrária ao movimento precedente, o que permite com maior eficiência, uso de indicadores e osciladores técnicos.

Tabela 7 - Decisão Ótima por Par Cambial

Par	Comprar	%Comprar	Manter	%Manter	Vender	%Vender	Total
AUD/CAD	1591	26,01%	2936	47,99%	1591	26,01%	6118
EUR/USD	1564	25,56%	2987	48,82%	1567	25,61%	6118
EUR/ZAR	1543	25,22%	3031	49,54%	1544	25,24%	6118
GBP/JPY	1524	24,91%	3070	50,18%	1524	24,91%	6118
NZD/CHF	1515	24,76%	3088	50,47%	1515	24,76%	6118
USD/BRL	1570	25,69%	2974	48,66%	1568	25,65%	6112

Observa-se na Tabela 7 uma distribuição equilibrada entre os sinais de Comprar e Vender, com ambos a oscilar em torno de 25% para todos os pares analisados. A recomendação predominante para todos os casos é Manter, representando aproximadamente metade de todos os sinais e variando entre 47,99% para AUD/CAD e 50,47% para NZD/CHF. Esta consistência nas percentagens entre os diferentes pares sugere que o método de análise utilizado produz resultados similares independentemente do instrumento financeiro. O

tamanho da amostra é substancial e uniforme, com 6.118 sinais para a maioria dos pares, exceto USD/BRL que apresenta 6.112 sinais. Esta distribuição equilibrada reflete a natureza característica do mercado *Forex*, conhecido pela sua ausência de tendências claramente definidas e sustentáveis ao longo do tempo. A equivalência entre sinais de Comprar e Vender ilustra como os pares oscilam frequentemente em intervalos de negociação, com movimentos que se compensam mutuamente.

A aplicação das Redes Neurais baseou-se no programa *Statistical Package for the Social Sciences* (SPSS), utilizando o modelo *Multilayer Perceptron* (MLP) e os indicadores técnicos (RSI, MME, MACD, *Bollinger Bands*®) como *inputs* e a Decisão (Comprar, Manter, Vender) como *output*.

Na metodologia utilizada para este estudo, foram desenvolvidas e treinadas várias configurações de Redes Neurais MLP para prever as decisões de negociação no *Forex*. O processo começou com a preparação dos dados, em que o conjunto de dados foi dividido em subconjuntos de treino, utilizado para parametrizar a rede, e de teste, para comparar o acerto da previsão com o observado, com um rácio de divisão de 70% para treino e 30% para teste.

Os tempos de cálculo dos modelos são relativamente curtos, variando de alguns milésimos de segundos a pouco mais de três segundos. Isto indica que os modelos são computacionalmente eficientes e podem ser treinados rapidamente com novos dados.

Foram configurados três processos distintos. No primeiro, o modelo foi ajustado para selecionar automaticamente o número de camadas ocultas, variando entre 1 e 50 iterações, com um máximo de 50 iterações. No segundo, o modelo foi testado com um número fixo de uma unidade de camada oculta, e o máximo de iterações foi ampliado para 100. Por fim, no terceiro processo, o modelo foi configurado com duas camadas ocultas, para avaliar o impacto desse ajuste nos resultados. As iterações referem-se ao número de vezes que o modelo ajusta os pesos das conexões entre os neurónios durante o treino, com o objetivo de minimizar o erro de previsão. A Figura 20, e a Figura 21 ilustram as diferentes configurações testadas nas Redes Neurais.

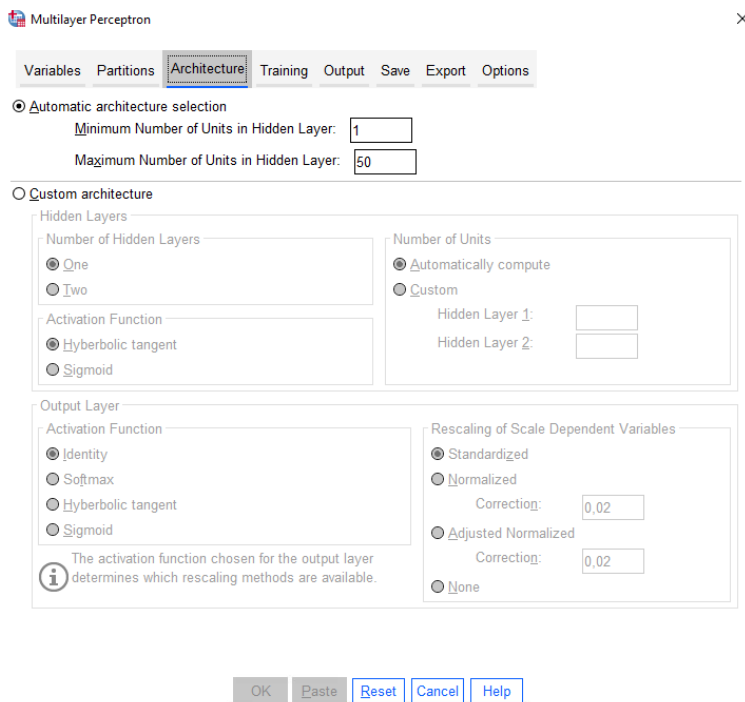


Figura 20 - 1 unidade de camada oculta, com um máximo de iterações de 50

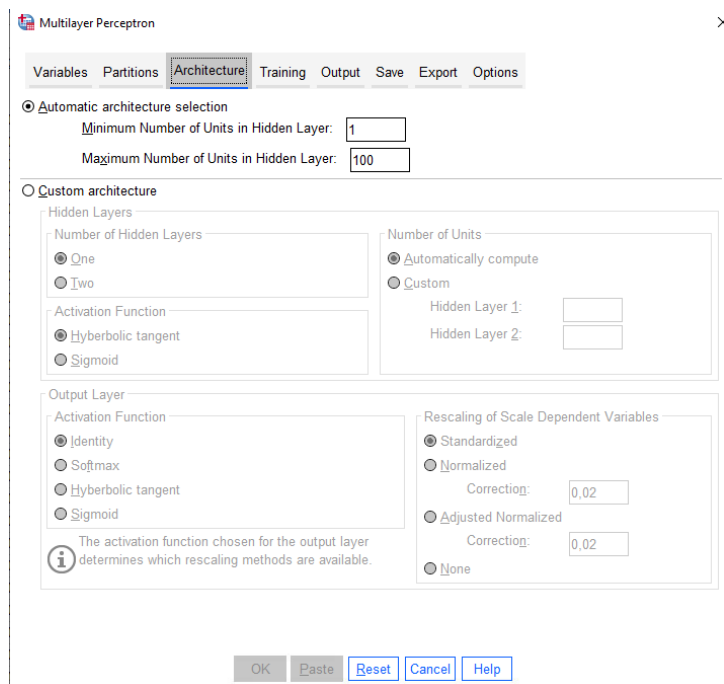


Figura 21 - 1 unidade de camada oculta, com um máximo de iterações de 100

A fase de treino e teste envolveu a utilização do treino em *Batch* (Figura 22). No treino em *Batch*, todos os dados de treino são utilizados para ajustar os pesos do modelo em cada iteração. Além disso, o modelo foi ajustado utilizando técnicas de gradiente.

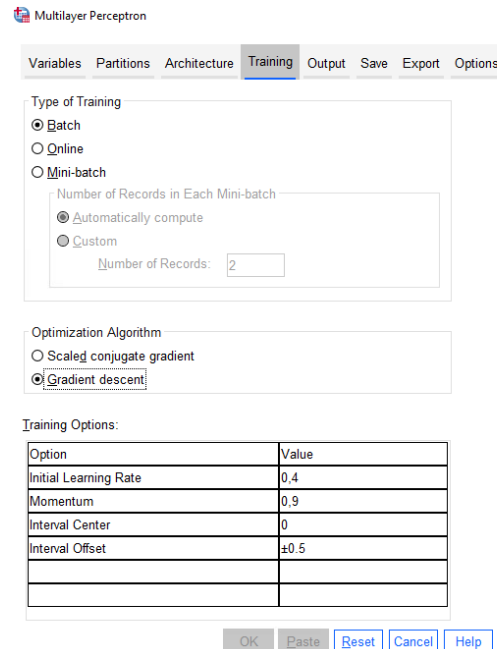


Figura 22 - Tipo de treino

O processo de treino continuou até ser atingido um critério de paragem predefinido, tal como um número específico de passos sem uma redução no erro de treino. Durante esta fase, foram utilizadas métricas de desempenho, como o erro de entropia cruzada e a percentagem de previsões incorretas, para avaliar a eficácia do modelo. O erro de entropia cruzada mede a diferença entre a probabilidade prevista pelo modelo e a classe real observada. No contexto desta dissertação, o erro foi usado para avaliar a precisão das previsões de Comprar, Manter e Vender em relação às decisões ótimas calculadas.

Por fim, os resultados foram analisados comparando a precisão preditiva dos modelos finais no conjunto de dados de teste.

3.2 Resultados

O desempenho geral dos modelos foi avaliado através de múltiplos indicadores, incluindo a percentagem de previsões corretas, variando significativamente entre as diferentes configurações analisadas. Na maioria dos casos, as taxas de acerto total variam entre 77,40% e 90,70%, com uma média global de 82,57%, conforme demonstrado na Tabela 8, Tabela 9 e Tabela 10. A análise destes resultados indica potencial para melhoria do desempenho preditivo através da implementação de períodos de treino mais extensos ou da adoção de metodologias de aprendizagem mais avançadas.

Tabela 8 - Resumo dos resultados com 1 camada oculta com um intervalo entre 1 a 50 iterações por velocidade de indicador

	1 camada com um intervalo entre 1 a 50 iterações					
	Treino			Teste		
	Rapido	Lento	Padrão	Rapido	Lento	Padrão
AUD/CAD	81,90%	81,00%	90,00%	82,60%	80,40%	89,70%
EUR/USD	82,30%	83,90%	86,10%	82,10%	83,20%	84,90%
EUR/ZAR	82,20%	80,20%	79,50%	81,90%	81,10%	80,20%
GBP/JPY	84,80%	79,40%	79,40%	83,50%	80,10%	78,90%
NZD/CHF	83,40%	83,90%	90,70%	84,10%	83,30%	89,90%
USD/BRL	82,30%	79,70%	77,40%	81,20%	78,40%	77,80%
Total	82,82%	81,35%	83,85%	82,57%	81,08%	83,57%
	82,67%			82,41%		

Tabela 9 - Resumo dos resultados com 1 camada oculta com um intervalo entre 1 a 100 iterações por velocidade de indicador

	1 camada com um intervalo entre 1 a 100 iterações					
	Treino			Teste		
	Rapido	Lento	Padrão	Rapido	Lento	Padrão
AUD/CAD	84,00%	86,60%	89,60%	84,00%	86,20%	89,10%
EUR/USD	84,90%	80,40%	87,00%	84,00%	79,70%	88,60%
EUR/ZAR	81,90%	79,00%	81,80%	82,20%	78,70%	81,30%
GBP/JPY	84,40%	79,50%	78,40%	83,30%	79,20%	79,10%
NZD/CHF	83,50%	81,00%	85,30%	82,60%	79,60%	84,00%
USD/BRL	86,00%	78,60%	78,10%	83,80%	79,40%	78,50%
Total	84,12%	80,85%	83,37%	83,32%	80,47%	83,43%
	82,78%			82,41%		

Tabela 10 - Resumo dos resultados com 2 camadas ocultas por velocidade de indicador

	2 camadas					
	Treino			Teste		
	Rapido	Lento	Padrão	Rapido	Lento	Padrão
AUD/CAD	85,10%	86,10%	89,50%	84,00%	85,80%	89,30%
EUR/USD	82,70%	80,00%	80,30%	83,70%	80,90%	79,90%
EUR/ZAR	83,90%	81,30%	79,20%	80,80%	81,00%	79,60%
GBP/JPY	81,30%	83,30%	80,10%	80,70%	80,90%	78,40%
NZD/CHF	84,50%	80,60%	90,20%	84,20%	80,90%	90,00%
USD/BRL	82,00%	79,20%	81,20%	82,30%	79,20%	81,20%
Total	83,25%	81,75%	83,42%	82,62%	81,45%	83,07%
	82,81%			82,38%		

Para a configuração de uma camada com 50 iterações, a média global, considerando todas as categorias, foi de 82,67% na fase de treino e 82,41% na fase de teste. Entre as categorias analisadas, a Padrão apresentou os melhores resultados tanto na fase de treino quanto na de teste. Durante o treino, alcançou uma média geral de 83,85%, com destaque para os pares NZD/CHF (90,70%) e AUD/CAD (90,00%). Na fase de teste, embora a média global tenha sido ligeiramente inferior, de 83,57%, a configuração manteve um bom desempenho, com o par NZD/CHF com a maior precisão (89,90%), seguido de perto pelo AUD/CAD (89,70%). Estes resultados indicam que, nesta configuração, a categoria Padrão foi a mais consistente, especialmente nos pares menores, como AUD/CAD e NZD/CHF.

Nas restantes categorias, Rápido e Lento, a transição do treino para a fase de teste também resultou numa ligeira queda nas médias gerais. Na categoria Rápido, as médias gerais foram de 82,82% na fase de treino e 82,57% na fase de teste. No entanto, alguns pares continuaram a apresentar bons resultados. O NZD/CHF destacou-se com 83,40% na fase de treino e 84,10% na fase de teste, enquanto o AUD/CAD obteve 81,90% no treino e 82,60% no teste. Um ponto interessante foi o desempenho do par GBP/JPY, que registou a melhor precisão na fase de treino (84,80%), embora tenha sofrido uma ligeira queda na fase de teste (83,50%).

Na categoria Lento, o desempenho foi um pouco inferior, com médias gerais de 81,35% na fase de treino e 81,08% na fase de teste. Ainda assim, o NZD/CHF manteve-se como um dos pares mais consistentes, com 83,90% na fase de treino e 83,30% na fase de teste. Resultados semelhantes foram observados no EUR/USD, que apresentou precisões com 83,90% no treino e 83,20% no teste. Por outro lado, os pares EUR/ZAR e USD/BRL demonstraram serem mais desafiantes para obter níveis elevados de precisão, independentemente da categoria utilizada.

Ao segmentar os resultados de acerto pelas posições Comprar, Manter e Vender, observa-se que, para a posição Manter, a previsão atingiu 100% em todas as configurações, tanto na fase de treino como na de teste. Para as posições Comprar, os valores variaram entre 53,7% e 80,6% no treino e 55,1% e 81,0% no teste, com médias de 65,30% no treino e 64,94% no teste. Os melhores desempenhos foram observados nos indicadores Padrão, enquanto os indicadores Lento apresentam valores inferiores. Na posição Vender, os resultados oscilaram entre 55,3% e 82,0% no treino e 51,4% e 80,3% no teste, com médias de 66,41% no treino e 65,61% no teste, ligeiramente superiores às médias da posição Comprar. Mais uma vez, os indicadores Padrão foram os mais eficazes, enquanto o Lento teve o pior desempenho, tanto nas posições de Comprar, quanto nas de Vender. Analisando os pares cambiais individualmente, o par NZD/CHF apresentou desempenhos consistentemente bons em todas as posições e indicadores. Por outro lado, pares como EUR/ZAR e USD/BRL demonstraram um desempenho inferior. O par AUD/CAD destacou-se positivamente na posição Vender, mas apresentou resultados inferiores para a posição Comprar.

Tabela 11 - Resumo dos resultados com 1 camada oculta com um intervalo entre 1 a 50 iterações por velocidade de indicador para posições Comprar

1 camada com um intervalo entre 1 a 50 iterações para posições "Comprar"						
	Treino			Teste		
	Rapido	Lento	Padrão	Rapido	Lento	Padrão
AUD/CAD	56,50%	58,30%	80,60%	56,20%	57,10%	80,10%
EUR/USD	70,90%	66,90%	72,00%	65,60%	66,60%	74,00%
EUR/ZAR	63,80%	65,80%	53,70%	58,60%	67,20%	55,10%
GBP/JPY	69,50%	59,90%	59,50%	68,60%	58,90%	59,10%
NZD/CHF	72,80%	64,50%	80,40%	73,20%	63,10%	81,00%
USD/BRL	62,90%	62,10%	55,30%	63,60%	64,50%	56,40%
Total	66,07%	62,92%	66,92%	64,30%	62,90%	67,62%
	65,30%			64,94%		

Tabela 12 - Resumo dos resultados com 1 camada oculta com um intervalo entre 1 a 50 iterações por velocidade de indicador para posições Manter

1 camada com um intervalo entre 1 a 50 iterações para posições "Manter"						
	Treino			Teste		
	Rapido	Lento	Padrão	Rapido	Lento	Padrão
AUD/CAD	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
EUR/USD	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
EUR/ZAR	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
GBP/JPY	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
NZD/CHF	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
USD/BRL	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
Total	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
	100,00%			100,00%		

Tabela 13 - Resumo dos resultados com 1 camada oculta com um intervalo entre 1 a 50 iterações por velocidade de indicador para posições Vender

1 camada com um intervalo entre 1 a 50 iterações para posições "Vender"						
	Treino			Teste		
	Rápido	Lento	Padrão	Rápido	Lento	Padrão
AUD/CAD	74,30%	68,40%	81,20%	76,20%	68,40%	80,30%
EUR/USD	60,40%	70,50%	72,60%	63,50%	67,40%	69,50%
EUR/ZAR	67,10%	55,30%	66,30%	67,10%	58,70%	64,70%
GBP/JPY	68,10%	57,10%	56,80%	67,80%	61,80%	58,20%
NZD/CHF	60,20%	70,50%	82,00%	63,00%	69,20%	78,10%
USD/BRL	68,10%	59,00%	57,50%	61,60%	51,40%	54,00%
Total	66,37%	63,47%	69,40%	66,53%	62,82%	67,47%
	66,41%			65,61%		

Na configuração de uma camada com 100 iterações, a média global considerando todas as categorias foi de 82,78% na fase de treino e 82,41% na fase de teste. Entre as categorias analisadas, a Rápido destacou-se com a melhor média geral durante o treino, atingindo 84,12%. Os pares USD/BRL e EUR/USD foram os mais precisos nesta fase, com 86,00% e 84,90%, respetivamente. Já na fase de teste, a configuração Rápido manteve um desempenho elevado, com uma média geral de 83,32%. Os pares AUD/CAD e EUR/USD lideraram, ambos com uma precisão 84,00%, seguidos por USD/BRL (83,83%) e GBP/JPY (83,30%). Um aspeto relevante desta configuração é que, entre as três analisadas (1 camada com 50 iterações, uma camada com 100 iterações e duas camadas ocultas), esta categoria foi a única em que todos os pares apresentaram resultados acima de 80%, tanto na fase de treino quanto na fase de teste. Este facto reflete um desempenho sólido e consistente, independentemente dos critérios utilizados.

Por outro lado, a configuração Padrão voltou a apresentar melhor desempenho na fase de teste e destacou-se em pares como AUD/CAD (89,10%), EUR/USD (88,60%) e NZD/CHF (84,00%) No entanto, registou desempenhos inferiores a 80%, em pares como GBP/JPY (79,10%) e USD/BRL (78,50%).

Relativamente à categoria Lento, esta manteve-se como a menos precisa (80,47%) na fase de teste. Apenas o par AUD/CAD conseguiu um resultado acima dos 80%, com uma precisão de 86,20%. Os restantes pares, com exceção do EUR/ZAR, que teve menor precisão (78,70%), registaram valores dentro dos 79%.

Relativamente às posições, o modelo atingiu 100% de previsão em todas as configurações para a posição Manter, tanto no treino quanto no teste, com exceção do par EUR/ZAR na fase de teste no indicador Rápido, que apresentou 99,9%. Para as posições Comprar, os resultados variam entre 50,2% e 79,8% no treino e entre 50,9% e 79,3% no teste, com uma média de 66,86% no treino e 66,27% no teste, apresentando um desempenho razoável, mas com espaço para melhorias. O par AUD/CAD obteve o melhor desempenho no indicador Padrão, com 80,6% no treino e 79,3% no teste, enquanto o EUR/ZAR teve o pior desempenho no mesmo indicador com 53,7% no treino e 58,9% no teste. Para as posições Vender, os resultados oscilaram entre 52,9% e 84,5% no treino e 40,7% e 84,2% no teste, com médias de 65,08% no treino e 64,46% no teste. Novamente, os indicadores Padrão foram os mais eficazes, enquanto os Lento tiveram o pior desempenho. Em relação ao desempenho dos pares cambiais, o AUD/CAD teve um desempenho consistentemente positivo em todas as posições e configurações. Por outro lado, o par EUR/ZAR apresentou o pior desempenho na posição Comprar e o par GBP/JPY na posição Vender.

Tabela 14 - Resumo dos resultados com 1 camada oculta com um intervalo entre 1 a 100 iterações por velocidade de indicador para posições Comprar

1 camada com um intervalo entre 1 a 100 iterações para posições "Comprar"						
	Treino			Teste		
	Rapido	Lento	Padrão	Rapido	Lento	Padrão
AUD/CAD	64,30%	74,80%	79,80%	64,70%	73,80%	79,30%
EUR/USD	68,30%	58,30%	74,90%	67,80%	57,10%	76,90%
EUR/ZAR	62,10%	50,20%	63,40%	63,50%	50,90%	58,90%
GBP/JPY	71,80%	60,00%	60,30%	69,60%	59,40%	63,70%
NZD/CHF	69,40%	69,40%	71,20%	67,70%	70,10%	66,30%
USD/BRL	78,40%	53,80%	73,10%	76,50%	54,90%	71,80%
Total	69,05%	61,08%	70,45%	68,30%	61,03%	69,48%
	66,86%			66,27%		

Tabela 15 - Resumo dos resultados com 1 camada oculta com um intervalo entre 1 a 100 iterações por velocidade de indicador para posições Manter

1 camada com um intervalo entre 1 a 100 iterações para posições "Manter"						
	Treino			Teste		
	Rapido	Lento	Padrão	Rapido	Lento	Padrão
AUD/CAD	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
EUR/USD	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
EUR/ZAR	100,00%	100,00%	100,00%	99,90%	100,00%	100,00%
GBP/JPY	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
NZD/CHF	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
USD/BRL	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
Total	100,00%	100,00%	100,00%	99,98%	100,00%	100,00%
	100,00%			99,99%		

Tabela 16 - Resumo dos resultados com 1 camada oculta com um intervalo entre 1 a 100 iterações por velocidade de indicador para posições Vender

1 camada com um intervalo entre 1 a 100 iterações para posições "Vender"						
	Treino			Teste		
	Rapido	Lento	Padrão	Rapido	Lento	Padrão
AUD/CAD	73,80%	73,30%	80,20%	74,60%	74,30%	79,40%
EUR/USD	72,00%	65,40%	74,50%	71,40%	62,90%	78,40%
EUR/ZAR	66,70%	65,30%	65,30%	66,40%	67,70%	67,00%
GBP/JPY	65,20%	57,40%	52,30%	63,60%	57,70%	53,30%
NZD/CHF	64,30%	52,90%	69,40%	61,60%	49,80%	69,40%
USD/BRL	66,70%	64,20%	42,60%	60,00%	62,00%	40,70%
Total	68,12%	63,08%	64,05%	66,27%	62,40%	64,70%
	65,08%			64,46%		

Por fim, na configuração de duas camadas, a média global das três categorias foi de 82,81% na fase de treino e 82,38% na fase de teste. Entre elas, a categoria Padrão voltou a apresentar os melhores resultados, alcançando uma média de 83,42% no treino e 83,07% no teste, com destaque para os pares NZD/CHF e AUD/CAD, que registaram precisões de 90,20% e 89,50%, respectivamente. Na fase de teste, a categoria Padrão continuou a liderar com uma média geral de 83,07%, sendo novamente o NZD/CHF o mais preciso (90,00%), seguido pelo AUD/CAD (89,30%).

Na categoria Rápido, os pares NZD/CHF e AUD/CAD também apresentaram os melhores desempenhos. Durante o treino, registaram 84,50% e 85,10%, respetivamente, enquanto na fase de teste alcançaram 84,20% e 84,00%.

Na categoria Lento, os resultados foram ligeiramente mais baixos. Durante o treino, os pares AUD/CAD e GBP/JPY destacaram-se com 86,10% e 83,30%, respetivamente. Na fase de teste, o AUD/CAD voltou a ser o mais preciso, com 85,50%, enquanto o EUR/ZAR foi o segundo melhor, com 81,00%.

Para a posição Manter, o modelo atingiu 100% de acerto em quase todas as configurações, tanto no treino quanto no teste, com exceção do par EUR/USD no teste com o indicador Rápido 99,9%, e do NZD/CHF no teste com o indicador Padrão 99,9%. Para a posição Comprar, os resultados variaram entre 48,2% e 79,9% no treino e entre 47,4% e 77,5% no teste, com uma média de 66,00% no treino e 65,94% no teste. Os pares AUD/CAD e o par NZD/CHF obtiveram os melhores desempenhos, com médias de 74,05% e 71,32% respetivamente. Por outro lado, o par GBP/JPY teve o pior desempenho com uma média de 54,58%, sendo que, no indicador Rápido, foi o único par a obter valores abaixo dos 50% tanto na fase de treino, quanto na fase de teste. Já para a posição Vender, os resultados oscilaram entre 52,9% e 84,5% no treino e entre 52,7% e 83,9% no teste, com uma média de 71,05% no treino e 65,26% no teste. Os pares AUD/CAD, e NZD/CHF destacaram-se novamente, com os melhores desempenhos, com médias de 74,72% e 71,10% respetivamente, enquanto o USD/BRL teve o pior desempenho, com uma média de 62,78%. Nesta configuração, o indicador Rápido apresentou melhores taxas de acerto para as posições de Vender, especialmente na fase de treino, onde todos os pares, exceto o par AUD/CAD apresentaram valores acima dos 80%. Já na posição Comprar os indicadores Padrão apresentaram as melhores taxas de acerto.

Tabela 17 - Resumo dos resultados com 2 camadas por velocidade de indicador para posições Comprar

2 camadas para posições "Comprar"						
	Treino			Teste		
	Rapido	Lento	Padrão	Rapido	Lento	Padrão
AUD/CAD	72,30%	73,10%	79,00%	68,90%	73,50%	77,50%
EUR/USD	67,60%	59,10%	63,80%	69,90%	63,40%	66,20%
EUR/ZAR	65,00%	65,70%	61,60%	59,70%	66,90%	62,80%
GBP/JPY	48,20%	64,30%	55,30%	47,40%	60,70%	51,60%
NZD/CHF	69,50%	64,00%	79,90%	72,90%	65,80%	75,80%
USD/BRL	68,80%	63,40%	67,40%	69,00%	65,10%	69,90%
Total	65,23%	64,93%	67,83%	64,63%	65,90%	67,30%
	66,00%			65,94%		

Tabela 18 - Resumo dos resultados com 2 camadas por velocidade de indicador para posições Manter

2 camadas para posições "Manter"						
	Treino			Teste		
	Rapido	Lento	Padrão	Rapido	Lento	Padrão
AUD/CAD	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
EUR/USD	100,00%	100,00%	100,00%	99,90%	100,00%	100,00%
EUR/ZAR	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
GBP/JPY	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
NZD/CHF	100,00%	100,00%	100,00%	100,00%	100,00%	99,90%
USD/BRL	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
Total	100,00%	100,00%	100,00%	99,98%	100,00%	99,98%
	100,00%			99,99%		

Tabela 19 - Resumo dos resultados com 2 camadas por velocidade de indicador para posições Vender

2 camadas para posições "Vender"						
	Treino			Teste		
	Rapido	Lento	Padrão	Rapido	Lento	Padrão
AUD/CAD	70,30%	73,40%	80,40%	69,60%	72,30%	82,30%
EUR/USD	82,70%	65,40%	72,60%	64,80%	61,60%	58,70%
EUR/ZAR	83,90%	65,30%	66,30%	67,90%	58,00%	56,80%
GBP/JPY	81,30%	57,40%	56,80%	75,20%	63,50%	63,80%
NZD/CHF	84,50%	52,90%	82,00%	65,30%	58,00%	83,90%
USD/BRL	82,00%	64,20%	57,50%	62,60%	52,70%	57,70%
Total	80,78%	63,10%	69,27%	67,57%	61,02%	67,20%
	71,05%			65,26%		

Em conclusão, as diferentes configurações de camadas demonstraram impactos distintos nos resultados. A configuração de 1 camada com 50 iterações, mostrou-se eficaz com uma precisão média global de 82,41% na fase de teste, destacando-se em pares como NZD/CHF, com uma precisão média de 85,77% e AUD/CAD com 84,23%. De forma semelhante, a configuração de uma camada com 100 iterações atingiu a mesma precisão global de 82,41% na fase de teste, com os pares AUD/CAD (86,43%), e EUR/USD (84,10%) a apresentarem os melhores desempenhos. Já a configuração de 2 camadas destacou-se como o modelo com melhor precisão na fase de treino, contudo, na fase de teste, o desempenho global foi ligeiramente inferior. Ainda assim, os pares AUD/CAD e NZD/CHF mantiveram-se em destaque, com médias globais de 86,37% e 85,07%, respetivamente. É importante notar que nesta configuração foi alcançado a maior precisão individual na fase de teste, com o par NZD/CHF a obter uma média global de 90%.

Os pares AUD/CAD e NZD/CHF apresentaram consistentemente as melhores taxas de acerto nas configurações analisadas. Esse desempenho pode ser atribuído à menor exposição a eventos económicos e geopolíticos. Em contraste, pares como USD/BRL e EUR/ZAR demonstraram menor precisão devido à alta volatilidade associada a fatores regionais, como instabilidades políticas e económicas. Esses resultados evidenciam que os pares menores são mais adequados para modelos preditivos baseados em indicadores técnicos.

Quanto às categorias, a Padrão foi a mais consistente em todas as configurações, enquanto a Rápido mostrou consistência ao longo de todos os cenários, com todos os pares acima de 80% na fase de treino e teste. Por outro lado, a categoria Lento foi a menos precisa,

apresentando dificuldades em captar variações rápidas nos preços. Esses resultados destacam a importância de ajustar as configurações às características dos pares cambiais e aos objetivos da análise. O facto de a categoria Rápido apresentar melhor desempenho que o Lento é corroborado pela literatura, uma vez que no estudo de Patel (2023) a MM de dias mais curtos, ou seja, de categoria Rápido, supera as MM de dias mais longos, ou seja, de categoria Lento.

Além disso, a análise por posição revelou que a previsão da posição Manter foi extremamente precisa, atingindo 100% na maioria das configurações. No entanto, as posições Comprar e Vender apresentaram variações significativas dependendo do par cambial e da configuração utilizada. A categoria Padrão obteve os melhores resultados para ambas as posições, enquanto a categoria Lento teve o pior desempenho, especialmente na posição Comprar, indicando que estratégias baseadas nesse indicador podem ser menos eficazes para decisões de compra imediatas.

Por forma a contextualizar os resultados obtidos em relação à categoria/velocidade dos indicadores, a Figura 23 serve como apoio para facilitar a compreensão. Uma das explicações para o maior poder de precisão dos indicadores na configuração Padrão está relacionada com a forma como foram originalmente concebidos e adotados por analistas e *traders*. No caso do RSI e do MACD, os seus criadores definiram os valores padrão desde o início: o RSI foi estabelecido por Wilder (1978) com o período de 14 dias, enquanto o MACD foi configurado por Appel (1979) com os períodos de 12, 26 e 9 dias. Esses valores foram cuidadosamente testados pelos seus autores e identificados como os períodos ótimos, oferecendo um equilíbrio ideal entre sensibilidade aos movimentos de preços e estabilidade nas análises. Como resultado, os indicadores na configuração Padrão conseguem capturar, de forma eficiente, tanto as flutuações de curto prazo quanto as tendências de longo prazo, tornando-se ferramentas robustas e confiáveis na análise técnica.




Figura 23 - Precisão da velocidade dos indicadores

Relativamente à precisão global dos pares cambiais (Figura 24), cada par analisado apresentou características únicas que influenciaram os resultados. Os dois pares que se destacam com maior precisão são os pares AUD/CAD e NZD/CHF (os pares menores), com 85,68% e 84,29% respectivamente na fase de teste. O EUR/USD teve um desempenho uniforme em todas as configurações, refletindo sua estabilidade e alta liquidez (Tabela 3), apresentou uma precisão alta com 83% na fase de teste e treino. Por último, os pares com menor precisão foram os 2 pares emergentes (EUR/ZAR e USD/ BRL), juntamente com o par principal GBP/JPY, contudo apresentam uma percentagem de acerto acima de 80% quer na fase de teste, quer na fase de treino.




Figura 24 - Precisão por par cambial

Após a análise realizada, explorou-se ainda a individualização dos indicadores, ou seja, aplicar cada indicador isoladamente aos pares cambiais. No caso do RSI foram testados períodos entre 2 e 20 dias; para as MME os períodos analisados são 5, 10, 20, 50, 100, 150, 200, 400 dias, no MACD foram utilizadas as combinações de períodos 5, 20, 8 dias; 12, 26, 9 dias; e 13, 50, 15 dias, e para as *Bollinger Bands*® os períodos analisados foram 10, 50 e 100 dias.

Conforme apresentado nas Tabela 20 e Tabela 21, o MACD foi o indicador mais robusto, tanto na fase de treino, como na fase de teste. Na fase de teste apresentou ligeira melhoria passando de 83,68% para 83,94% de precisão. Os pares com melhor desempenho foram os mesmo das duas fases, o NZD/CHF (86,90%), o AUD/CAD (86,60%), e o EUR/USD (86,13%), todos com valores cima de 86% na fase de teste.

De seguida o segundo melhor desempenho foi observado nas MME, que também apresentou uma ligeira melhoria de precisão na fase de teste, passando de 82,18% na fase de treino para 82,22%. Os pares com maior precisão foram o AUD/CAD (86,90%) e o NZD/CHF (85,40%), seguidos pelo GBP/JPY (82,37%) e o EUR/USD (82,17%).

Já o RSI foi o terceiro melhor indicador, com uma precisão de 81,59% na fase de teste, ligeiramente inferior à fase de treino, com 81,93%. Neste caso, os seis pares cambiais

apresentaram precisões relativamente semelhantes, destacando-se o NZD/CHF (82,83%) e o GBP/JPY (81,50%) com os melhores desempenhos.

Por fim, as *Bollinger Bands*® foram o indicador com pior desempenho, apresentando uma precisão global abaixo dos 80%, situando-se nos 78,15% na fase de teste. Apenas os pares NZD/CHF e AUD/CAD apresentaram valores acima dos 80%, com 82,57% e 82,10%, respectivamente. Os restantes pares apresentaram valores inferiores, no intervalo de 75% a 76%.

Tabela 20 - Resultados Individual dos Indicadores por Pares Cambiais (Treino)

	Treino				
	RSI	MME	MACD	Bollinger	Total
AUD/CAD	80,97%	87,17%	86,27%	82,47%	84,22%
EUR/USD	80,87%	82,43%	86,47%	77,97%	81,93%
EUR/ZAR	82,93%	77,07%	80,60%	76,37%	79,24%
GBP/JPY	82,70%	81,13%	81,23%	76,80%	80,47%
NZD/CHF	82,17%	86,37%	86,87%	83,10%	84,63%
USD/BRL	81,93%	78,93%	80,67%	73,90%	78,86%
Total	81,93%	82,18%	83,68%	78,43%	81,56%

Tabela 21 - Resultados Individual dos Indicadores por Pares Cambiais (Teste)

	Teste				
	RSI	MME	MACD	Bollinger	Total
AUD/CAD	81,27%	86,90%	86,60%	82,10%	84,22%
EUR/USD	80,97%	82,17%	86,13%	76,10%	81,34%
EUR/ZAR	81,37%	77,30%	80,50%	76,90%	79,02%
GBP/JPY	81,50%	82,37%	82,60%	75,13%	80,40%
NZD/CHF	82,83%	85,40%	86,90%	82,57%	84,43%
USD/BRL	81,63%	79,17%	80,90%	76,10%	79,45%
Total	81,59%	82,22%	83,94%	78,15%	81,48%

O desempenho superior do MACD como indicador isolado, particularmente nos pares NZD/CHF, AUD/CAD e EUR/USD, reflete a sua capacidade de identificar mudanças de tendência com maior precisão. Esse resultado pode ser explicado pela utilização de MM de períodos otimizados, que suavizam as flutuações de curto prazo. Por outro lado, os resultados menos expressivos das *Bollinger Bands*®, poderão ser explicados pela sua maior reatividade a movimentos extremos, no entanto, em contextos onde os preços oscilam dentro de faixas

claras suporte e resistência, as *Bollinger Bands*® podem oferecer *insights* mais relevantes. Esses resultados sugerem que o uso individual de indicadores deve ser cuidadosamente alinhado ao contexto de cada par cambial.

Ao analisarmos os resultados do uso conjunto de indicadores em comparação com o uso individualizado dos indicadores, observa-se uma precisão global ligeiramente superior na utilização conjunta, com 82,40% contra 81,48%. Isso demonstra que o uso combinado dos indicadores oferece uma vantagem moderada em termos de precisão, sugerindo que a integração de diferentes ferramentas permite captar uma gama mais ampla de sinais do mercado, melhorando as previsões.

Os resultados destacam que a escolha da configuração de camadas ocultas e da categoria de indicadores técnicos desempenha um papel crucial na previsão de decisões de investimento. Em termos práticos, a análise reforça a ideia de que os indicadores técnicos não devem ser utilizados isoladamente, mas como ferramentas complementares a outras abordagens, como a análise fundamental e a gestão de risco. É importante salientar que a ausência de dados sobre volumes de negociação limita o alcance das análises realizadas. Apesar disso, os resultados sugerem que a integração futura desses dados poderia melhorar a precisão e a eficácia dos modelos aplicados.

4. Conclusão

Este estudo investigou a eficácia de várias estratégias de negociação no mercado *Forex* através das Redes Neurais, centrando-se nos pares cambial AUD/CAD, EUR/USD, EUR/ZAR, GBP/JPY, NZD/CHF e USD/BRL ao longo de 24 anos. Os resultados oferecem informações importantes sobre a aplicabilidade e as limitações das Redes Neurais na previsão financeira. A análise revelou que as taxas de erro média globais dos modelos de Redes Neurais rondam os 18%, indicando a necessidade de melhorar a precisão da previsão.

Existiram diversas dificuldades ao longo da realização desta dissertação, nomeadamente a falta de conhecimento prévio sobre as Redes Neurais e a sua programação. Foram feitas tentativas de utilizar outras ferramentas que não exigem programação, como o *NeuralTools*, contudo, os resultados apresentaram taxas de acerto relativamente baixas. Essa limitação evidenciou a complexidade de utilizar ferramentas que exigem muito conhecimento técnico, reforçando a necessidade de aprofundar os conhecimentos em técnicas de *machine learning* para desenvolver modelos que sejam mais eficazes.

Este estudo acrescenta valor à literatura sobre previsões financeiras e negociação algorítmica, evidenciando a capacidade das Redes Neurais na antecipação de decisões de negociação no mercado *Forex*. Os resultados mostram o potencial das Redes Neurais como uma ferramenta poderosa para a negociação, enquanto sublinham a importância de uma investigação contínua e de novos desenvolvimentos para superar as limitações identificadas. Com o aprimoramento dos modelos e a exploração de novas abordagens, é possível desenvolver estratégias de negociação mais precisas e resilientes, capazes de lidar eficazmente com as complexidades dos mercados financeiros.

Para complementar este trabalho, refere-se o interesse no desenvolvimento de métodos de previsão, ou técnicas que permitam otimizar os *inputs* nos modelos apresentados, com vista à obtenção de taxas de acerto superiores às obtidas nesta dissertação. Esta abordagem poderia incluir o uso de técnicas mais avançadas de *machine learning*. Adicionalmente, seria interessante realizar uma análise comparativa utilizando os mesmos pares cambiais, mas substituindo os indicadores técnicos por uma abordagem baseada na análise fundamental. Essa análise incluiria dados económicos e macroeconómicos dos países envolvidos, como

PIB, crescimento das importações e exportações, taxas de juros, inflação, entre outros indicadores relevantes. O objetivo seria avaliar qual das abordagens, técnica ou fundamental, apresenta maior capacidade preditiva em diferentes cenários de mercado.

Além disso, a combinação das duas metodologias – análise técnica e análise fundamental – pode ser explorada, para desenvolver modelos híbridos que integrem os pontos fortes de ambas. Enquanto os indicadores técnicos permitem identificar padrões e tendências no curto prazo, as variáveis fundamentais fornecem *insights* sobre movimentos de longo prazo, influenciados por fatores macroeconômicos. A adoção desta abordagem não só pode aumentar a precisão das previsões, como também fornecer uma visão mais robusta sobre o comportamento dos pares cambiais no mercado *Forex*.

Por fim, para validar essas propostas, seria fundamental realizar testes adicionais com diferentes conjuntos de dados, ampliando o período de análise ou diversificando os pares cambiais incluídos, de forma a garantir que as conclusões possam ser estendidas para diferentes condições de mercado. Este esforço pode contribuir para validar o interesse da aplicação de redes neurais no mercado *Forex*.

Referências Bibliográficas

- Achelis, S. (2013). *Technical analysis from A to Z* (2nd ed.). McGraw-Hill Education.
- Ammenwerth, E., Gräber, S., Herrmann, G., Bürkle, T., & König, J. (2003). Evaluation of health information systems—problems and challenges. *International Journal of Medical Informatics*, 71(2-3), 125–135.
- Andersen, T. G., Bollerslev, T., Diebold, F. X., & Vega, C. (2003). Micro effects of macro announcements: Real-time price discovery in foreign exchange. *American Economic Review*, 93(1), 38-62.
- Appel, G. (1979). *The Moving Average Convergence-Divergence Trading Method*. Scientific Investment Systems.
- Bank for International Settlements. (2022, Outubro 27). *Foreign exchange turnover in April 2022: Preliminary global result. Triennial Central Bank Survey*. https://www.bis.org/statistics/rpForex22_Forex.pdf
- Berradi, Z., Lazaar, M., Mahboub, O., & Omara, H. (2020). A comprehensive review of artificial intelligence techniques in financial market. In *2020 6th IEEE congress on information science and technology (CiSt)* (pp. 367-371). IEEE.
- Bollinger, J. (1992). Using Bollinger Bands. *Technical Analysis of Stocks & Commodities*, 10(2), 47-51.
- Buffet, W. (1986). *Berkshire Hathaway shareholder letter*. Berkshire Hathaway.
- Campbell, J. Y., Lo, A. W., & MacKinlay, A. C. (1997). *The econometrics of financial markets*. Princeton University Press.
- Chen, Y.-C., & Tsang, K. P. (2013). What does the yield curve tell us about exchange rate predictability? *The Review of Economics and Statistics*, 95(1), 185–205.
- Chen, S., Chen, N., & Chuang, R. (2014). An empirical study on technical analysis: GARCH (1,1) model. *Journal of Applied Statistics*, 41(4), 785-801.

Cho, K., van Merriënboer, B., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. arXiv preprint arXiv:1406.1078.

Chong, T. T.-L., & Ng, W.-K. (2008). Technical analysis and the London stock exchange: Testing the MACD and RSI rules using the FT30. *Applied Economics Letters*, 15(14), 1111–1114.

Chong, T. T.-L., Ng, W.-K., & Liew, V. K.-S. (2014). Revisiting the performance of MACD and RSI oscillators. *Journal of Risk and Financial Management*, 7(1), 1-12.

Chung, C.-P., Chien, C.-Y., Huang, C.-H., & Lee, H.-C. (2021). Foreign institutional ownership and the effectiveness of technical analysis. *The Quarterly Review of Economics and Finance*, 82, 86-96.

Clarida, R., Galí, J., & Gertler, M. (2000). Monetary policy rules and macroeconomic stability: Evidence and some theory. *Quarterly Journal of Economics*, 115(1), 147-180.

Coakley, J., Marzano, M., & Nankervis, J. (2016). How profitable are FX technical trading rules? *International Review of Financial Analysis*, 45, 273-282.

Covel, M. (2007). *The complete TurtleTrader: The legend, the lessons, the results*. HarperCollins Publishers.

Dastres, R., & Soori, M. (2021). Artificial neural network systems. *International Journal of Imaging and Robotics*, 21(2), 13-25.

De Bondt, W. F., & Thaler, R. (1985). Does the stock market overreact? *Journal of Finance*, 40(3), 793-805.

Deboeck, G. (1994). *Trading on the edge: Neural, genetic and fuzzy systems for chaotic financial markets*. Wiley.

Elton, E. J., Gruber, M. J., & Blake, C. R. (1996). The Persistence of Risk-Adjusted Mutual Fund Performance. *The Journal of Business*, 69(2), 133–157.

- Engel, C., & West, K. D. (2005). Exchange rates and fundamentals. *Journal of Political Economy*, 113, 485-517.
- Evans, M. D., & Lyons, R. K. (2008). How is macro news transmitted to exchange rates? *Journal of Financial Economics*, 88(1), 26-50.
- Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *The Journal of Finance*, 25, 383-417.
- Fama, E. F., & French, K. R. (1988). Permanent and temporary components of stock prices. *Journal of Political Economy*, 96, 246-273.
- Faru, S. H., Waititu, A., & Nderu, L. (2023). A hybrid neural network model based on transfer learning for forecasting forex market. *Journal of Data Analysis and Information Processing*, 11, 103-120.
- Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654-669.
- Frankel, J. (2015). *The Plaza Accord, 30 years later* (NBER Working Paper No. 21813). National Bureau of Economic Research.
- Graham, B., & Dodd, D. (1934). *Security analysis*. McGraw-Hill.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.
- IBM. (n.d.-a). *What is overfitting?* <https://www.ibm.com/topics/overfitting>
- IBM. (n.d.-b). *What are convolutional neural networks?* <https://www.ibm.com/think/topics/convolutional-neural-networks>
- Jegadeesh, N., & Titman, S. (1993). Returns to buying winners and selling losers: Implications for stock market efficiency. *The Journal of Finance*, 48(1), 65-91.
- Kahneman, D., & Tversky, A. (1979). Prospect theory: An analysis of decision under risk. *Econometrica: Journal of the Econometric Society*, 47, 263-292.

Kamruzzaman, J., & Sarker, R. A. (2003). Forecasting of currency exchange rates using ANN: A case study. *Proceedings of IEEE International Conference on Neural Networks & Signal Processing (ICNNSP03)*, 793-797.

Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. In *International Conference on Neural Networks* (pp. 1942–1948). IEEE Press.

King, M. R., Osler, C. L., & Rime, D. (2011). Foreign exchange market structure, players and evolution. In J. James, I. W. Marsh, & L. Sarno (Eds.), *Handbook of exchange rates* (pp. 3-44). John Wiley & Sons.

Kumar, N. B., & Mohapatra, S. (2015). *The use of technical and fundamental analysis in the stock market in emerging and developed economies*. Emerald Group Publishing.

Lane, P. R. (2006). The real effects of European Monetary Union. *Journal of Economic Perspectives*, 20(4), 47-66.

Lien, K. (2008). *Day trading and swing trading the currency market* (2nd ed.). John Wiley & Sons.

Malkiel, B. (1996) *A Random Walk down the Wall Street*. 6th Edition, W. W Norton, New York.

Markova, M. (2019, October). AIP Conference Proceedings 2164, 060010.

Menkhoff, L., & Taylor, M. P. (2007). The obstinate passion of foreign exchange professionals: Technical analysis. *Journal of Economic Literature*, 45(4), 936-972.

Mohammed A, Othman Z, Abdullah A. (2024) The Role of Artificial Intelligence in Enhancing Sports Analytics and Training. *Cihan University-Erbil scientific journal*.

Murphy, J. J. (1999). *Technical analysis of the financial markets: A comprehensive guide to trading methods and applications*. New York Institute of Finance.

Nanda, S., & Peters, D. (2006). A very long-term buy-and-hold portfolio. *Journal of Portfolio Management*, 32, 65-73.

Neely, C. J., Weller, P. A., & Ulrich, J. M. (2009). The adaptive markets hypothesis: Evidence from the foreign exchange market. *Journal of Financial and Quantitative Analysis*, 44(2), 467-488.

Neely, C. J., & Weller, P. A. (2011). Technical analysis in the foreign exchange market. Federal Reserve Bank of St. Louis Working Paper Series.

Ni, L., Li, Y., Wang, X., Zhang, J., Yu, J., & Qi, C. (2019). Forecasting of forex time series data based on deep learning. *Procedia Computer Science*, 147, 647-652.

Nuraeni, N., Astuti, P., Irnawati, O., Darwati, I., & Harmoko, D. D. (2020). High accuracy in forex predictions using the neural network method based on particle swarm optimization. *Journal of Physics: Conference Series*, 1641(1), 012067.

Okunev, J., & White, D. (2003). Do momentum-based strategies still work in foreign currency markets? *Journal of Financial and Quantitative Analysis*, 38(2), 425-447.

Patel, S. (2023). Trading strategies using technical indicators: An active portfolio management approach. *The Journal of Wealth Management*, 26(2), 138–151.

Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386-408.

Ryll, L., & Seidens, S. (2019). Evaluating the performance of machine learning algorithms in financial market forecasting: A comprehensive survey.

Saxo Group. (n.d.). *A guide to the 10 most popular trading indicators*. <https://www.home.saxo/learn/guides/trading-strategies/a-guide-to-the-10-most-popular-trading-indicators>

Sezer, O. B., Ozbayoglu, M., & Dogdu, E. (2017). A deep neural-network based stock trading system based on evolutionary optimized technical analysis parameters. *Procedia Computer Science*, 114, 473–480.

Sezer, O. B., & Ozbayoglu, A. M. (2018). Algorithmic financial trading with deep convolutional neural networks: Time series to image conversion approach. *Applied Soft Computing*, 70, 525–538.

Silva, M., & Nunes, P. (2020). *Ganhar na bolsa com análise técnica* (4ª ed.). Bookout.

Stanković, J., Marković, I., & Stojanović, M. (2015). Investment strategy optimization using technical analysis and predictive modeling in emerging markets. *Procedia Economics and Finance*, 19, 51-62.

Vajda, V. (2014). Could a trader using only “old” technical indicator be successful at the Forex market? *Procedia Economics and Finance* 15, 318 – 325.

Vuković, D., Grubišić, Z., & Jovanović, A. (2012). The use of moving averages in technical analysis of securities. *Megatrend Review*, 9(1), 319-337.

Wilder, J. W. (1978). *New concepts in technical trading systems*. Trend Research.

Yazdi, S. H., & Lashkari, Z. H. (2013). Technical analysis of Forex by MACD indicator. *International Journal of Humanities and Management Sciences*, 1(2), 159-165.