

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE ENGENHARIA CAMPUS DE ILHA SOLTEIRA**

LUIZ FRANCISCO FELTRIM JUNIOR

**PREVISÃO DE PREÇOS DE AÇÕES DA BOLSA DE VALORES POR REDES
NEURAIS ARTIFICIAIS**

Ilha Solteira

2022



UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Câmpus de Ilha Solteira

PREVISÃO DE PREÇOS DE AÇÕES DA BOLSA DE VALORES POR REDES NEURAIS ARTIFICIAIS

Trabalho de Graduação apresentado à Faculdade de Engenharia de Ilha Solteira-UNESP, como requisito parcial à obtenção do título de Bacharel em Engenharia Elétrica.

Orientadora: Prof.^a. Dra. Anna Diva Plasencia Lotufo.

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

F328p Feltrim Junior, Luiz Francisco.
Previsão de preços de ações da bolsa de valores por redes neurais artificiais
/ Luiz Francisco Feltrim Junior. -- Ilha Solteira: [s.n.], 2022
74 f. : il.

Trabalho de conclusão de curso (graduação em Engenharia Elétrica) -
Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira, 2022

Orientadora: Anna Diva Plasencia Lotufo
Inclui bibliografia


1. Mercado de ações. 2. Previsão. 3. Redes neurais artificiais. 4. Feedforward.
5. Backpropagation. 6. Bova11.



Erika Renata Bocchi Lomba
Diretora Técnica de Biblioteca e Documentação
Seção Técnica de Aquisição e Tratamento da Informação
Supervisora Técnica de Seção
CRB/8 -10792


ATA DE DEFESA DE TRABALHO DE GRADUAÇÃO

Aos dezenove dias do mês de dezembro do ano de dois mil e vinte e dois, o discente *Luiz Francisco Feltrim Junior*, matriculado sob o nº 151050945, tendo como banca examinadora a sua orientadora, a Profª. Drª. Anna Diva Plasencia Lotufo, a Doutoranda Danieli Biagi Vilela e o Doutorando Giovanni Panegossi Formaggio, apresentou o Trabalho de Graduação intitulado: **"PREVISÃO DE PREÇOS DE AÇÕES DA BOLSA DE VALORES POR REDES NEURAIS ARTIFICIAIS"** obtendo a nota 90 (NOVE) e conceito APROVADO.


Prof. Drª. Anna Diva Plasencia Lotufo
- orientadora -


Luiz Francisco Feltrim Junior
- discente -


Doutoranda Danieli Biagi Vilela
- Membro da Banca -


Doutorando Giovanni Panegossi Formaggio
- Membro da Banca -

Dedico a mim mesmo, que mesmo com todos os desafios
e problemas que me cercaram nesses anos de faculdade,
fui capaz de vencer os meus próprios demônios.

AGRADECIMENTOS

Agradeço principalmente as pessoas que me apoiaram nesse período tão difícil da minha vida que foi a faculdade, agradeço a minha mãe Marivete pela criação que me deu, ao meu falecido pai Luiz por ter me deixado condições de cursar uma faculdade, a Claudia por ter me apoiado e aguentado todos problemas que vieram nesses últimos 4 anos de faculdade, a minha irmã Jessica por ter aguentado as dificuldades geradas pela morte do meu pai e agradeço também ao meu amigo Matheus aquele que encarou os desafios acadêmicos comigo.

Agradeço aos meus tios e tias, Valquir por ter sido uma imagem paterna após a perda do meu pai, Marivilda por me dar o suporte em muitas coisas que minha mãe não conseguia e minha tia Marivania que me deu uma visão diferente da vida que eu poderia ter na faculdade.

Agradeço ao M.e. Giovanni por ter me ajudado tanto na elaboração desse trabalho, muitas vezes dedicando tempo em finais de semana para me ajudar.

Agradeço a professora doutora Anna Diva por ter me dado um chance com esse trabalho, mesmo eu não tendo sido um bom aluno durante a graduação.

Agradeço por último, a república Casa da Mãe Joana, onde morei por grande parte da minha graduação, onde apesar dos problemas e brigas, foi um local de aprendizado e começo de muitas amizades.

RESUMO

Prever o comportamento do mercado de ações, é uma das grandes questões abordadas por investidores do mercado. A digitalização e o uso crescente de diferentes tecnologias para esse fim vem crescendo, acompanhando aumento do acesso à computadores com poder computacional elevado o suficiente para esse fim. A substituição do conhecimento e experiência de um investidor por uma previsão executada por meio de uma máquina, torna o processo mais eficiente e confiável pois não expõe a previsão à fatores de erro inerentes do ser humano. O uso de redes neurais artificiais (RNAs) em especial tem sido um tópico de atenção entre os usuários de tecnologia para previsão no mercado de ações, nos últimos 10 anos se viu uma crescente do uso desse método. Nesse trabalho se propõe o uso da RNA do tipo *MLP* com arquitetura *feedforward* e treinamento via *backpropagation*, onde a série histórica do ativo BOVA 11 é o escolhido para uma previsão de valor de fechamento do dia seguinte; foi observado que com a divisão em períodos específicos, com tendências bem definidas da série, os resultados foram melhores, além da adição de variáveis para distinguir os dias úteis e dias da semana dos dados de entrada, no final foi obtido resultados satisfatórios em alguns cenários com taxas de *MDA* acima de 50%, além de taxas de *MAPE* inferiores a 2% para todas as divisões de período da série histórica nos melhores cenários para cada período.

Palavras-chave: Mercado de ações. Previsão. Redes neurais artificiais. *Feedforward*. *Backpropagation*. BOVA11. *MAPE*. *MDA*.

ABSTRACT

Predicting the behavior of the stock market, is one of the biggest questions approached by the market investors, the digitalization and crescent use of different technologies for this end has been increasing, accompanying a rise of the access to computers with sufficient elevated power. The substitution of the investor's knowledge and experience by a prediction executed by a machine, makes the process more efficient and reliable, because it takes off inherent mistake factors of the human being. The use of artificial neural networks (ANN) specially has been a topic of attention between technology users, specifically for predictions on the stock market, with a growing use in the last 10 years. On this work its proposed the use of an artificial neural network of the type MLP with a feedfoward architecture and backpropagation training, where the historic series is of the BOVA 11 asset is chosen for a prediction of the closing value, it was observed with the split of the series on intervals of well-defined tendencies, the results got better, besides the addition of input variables to distinguish between business days and week days, at the end it was achieved satisfactory results in some scenarios with MDA above 50%., besides a MAPE lower than 2% for all the intervals of historic series on the best scenarios for each interval.

Keywords: Stock market. Prediction. Artificial neural networks. Feedfoward. Backpropagation. BOVA11. MAPE. MDA.

LISTA DE TABELAS

Tabela 1 – Amostra dos dados da ação BOVA 11 retirados do <i>Yahoo Finance</i>	27
Tabela 2 – Amostra dos dados da ação BOVA 11 retirados do <i>Yahoo Finance</i>	28
Tabela 3 – Conjunto dos dados da ação BOVA 11 para o cenário 1.	29
Tabela 4 – Resultados agregados para o formato de uma camada oculta do cenário 1.	37
Tabela 5 – Resultados agregados para o formato de duas camadas ocultas do cenário 1.	40
Tabela 6 – Resultados agregados para o formato de uma camada oculta do cenário 2.	44
Tabela 7 – Resultados agregados para o formato de duas camadas ocultas do cenário 2.	47
Tabela 8 – Resultados agregados para o formato de uma camada oculta do cenário 3.	50
Tabela 9 – Resultados agregados para o formato de duas camadas ocultas do cenário 3.	54
Tabela 10 – Resultados agregados para o formato de uma camada oculta do cenário 4.	57
Tabela 11 – Resultados agregados para o formato de duas camadas ocultas do cenário 4.	60
Tabela 12 – Resultados agregados considerando o <i>MAPE</i> para todos os cenários e formatos.	61
Tabela 13 – Resultados agregados considerando o <i>MDA</i> para todos os cenários e formatos.	62

LISTA DE ILUSTRAÇÕES

Figura 1 – Neurônio biológico.....	13
Figura 2 – Neurônio artificial.....	14
Figura 3 – Função relé.	15
Figura 4 – Função lógica threshold.	16
Figura 5 – Função sigmoide.....	16
Figura 6 – Histórico de valor do ativo BOVA 11 no período de 2008 à 2022.	21
Figura 7 – Histórico da ação BOVA 11 no período de 2008 à 2016.....	22
Figura 8 – Histórico da ação BOVA 11 no período de 2016 à 2022.....	23
Figura 9 – Histórico da ação BOVA 11 no período a partir de abril de 2020.....	24
Figura 10 – Histórico da ação BOVA 11 no período a partir de agosto de 2020.....	25
Figura 11 – Fluxo de execução do cenário 1.....	26
Figura 12 – Diagrama da rede neural com a configuração de uma camada oculta.	30
Figura 13 – Diagrama da rede neural com a configuração de duas camadas ocultas.	31
Figura 14 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2022.....	34
Figura 15 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2016.....	35
Figura 16 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2016 à 2022.....	35
Figura 17– Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 04/2020 à 2022.....	36
Figura 18 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 08/2020 à 2022.....	36
Figura 19 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2022.....	38
Figura 20 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2016.....	38
Figura 21 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2016 à 2022.....	39
Figura 22 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 04/2020 à 2022.....	39
Figura 23 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 08/2020 à 2022.....	40
Figura 24 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2022.....	41
Figura 25 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2016.....	42
Figura 26 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2016 à 2022.....	42
Figura 27 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 04/2020 à 2022.....	43

[illegible]

Figura 51 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2016 à 2022.....	59
Figura 52 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 04/2020 à 2022.....	59
Figura 53 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 08/2020 à 2022.....	60

SUMÁRIO

1	INTRODUÇÃO	4
1.1	OBJETIVO	5
1.2	ORGANIZAÇÃO DO TRABALHO	5
2	SETOR DE AÇÕES	7
2.1	BOVA 11	7
2.2	BANCO CENTRAL	7
2.3	MERCADO DE AÇÕES	7
2.4	COMPORTAMENTO DAS AÇÕES	8
2.5	PREVISÃO NO MERCADO DE AÇÕES	10
3	REDES NEURAIS ARTIFICIAIS.....	12
3.1	MODELO BIOLÓGICO E MODELO ARTIFICIAL.....	12
3.2	ARQUITETURA DA RNA	16
3.3	TIPOS DE TREINAMENTO DAS REDES NEURAIS ARTIFICIAIS	17
3.4	TREINAMENTO DO TIPO <i>BACKPROPAGATION</i>	17
3.5	USO DE REDES NEURAIS PARA PREVISÃO DE VALORES DE AÇÃO ..	18
4	METODOLOGIA E AMBIENTE DE ESTUDO	20
4.1	ANÁLISE DA BASE DE DADOS E AMBIENTE DE ESTUDO	20
4.2	CENÁRIO 1.....	26
4.2.1	Definição dos padrões de entrada	27
4.2.2	Preenchimento dos dados faltantes.....	27
4.2.3	Adequação da base de dados	27
4.2.4	Criação dos padrões de entrada e saída.....	28
4.2.5	Normalização dos dados	29
4.2.6	Criação dos conjuntos de treinamento e teste	29
4.2.7	Configuração da RNA.....	30
4.3	CENÁRIO 2, 3 E 4.....	32
4.4	AVALIAÇÃO DO DESEMPENHO DA PREVISÃO	32
5	RESULTADOS E DISCUSSÕES.....	34
5.1	CENÁRIO 1.....	34
5.1.1	Formato com uma camada oculta	34
5.1.2	Formato com duas camadas ocultas	37
5.2	CENÁRIO 2.....	41
5.2.1	Formato com uma camada oculta	41

5.2.2	Formato com duas camadas ocultas	44
5.3	CENÁRIO 3.....	47
5.3.1	Formato com uma camada oculta	47
5.3.2	Formato com duas camadas ocultas	51
5.4	CENÁRIO 4.....	54
5.4.1	Formato com uma camada oculta	54
5.4.2	Formato com duas camadas ocultas	58
5.5	RESULTADOS COMPARATIVOS ENTRE OS CENÁRIOS	61
6	CONCLUSÃO	63
	REFERÊNCIAS.....	64

1 INTRODUÇÃO

Desde seu início, o mercado de ações e seu comportamento, serviu de forma de negócio e tema de pesquisa para muitos. A ambição por prever o comportamento desse mercado, para possibilitar ganhos consistentes, se tornou tema recorrente nos últimos anos com o avanço tecnológico, mesmo com os inúmeros fatores que influenciam esse mercado. Abrangendo esses fatores que decidem o comportamento do mercado de ações, estão desde decisões políticas até a forma de consumo da população, seja por meio de índices de inflação, câmbio ou até a taxa de desemprego local (PÉREZ, 2017).

O comportamento muitas vezes errático do mercado de ações, leva muitos economistas e especialistas a utilizarem, da própria experiência e conhecimento para tomada de decisões, porém esse tipo de método, sofre das fraquezas inerentes ao próprio ser humano, seja de origem emocional, psicológica ou física. Com isso o uso de RNAs, para a execução de previsões de ativos bolsistas, se torna uma alternativa mais viável, pois com o poder computacional presente nas máquinas que temos nos dias atuais, somado a capacidade de analisar e detectar padrões das RNAs (HAYKIN, 2009), o desempenho com um grande volume de dados que se tem do mercado de ações, se torna menos dependente do conhecimento e experiência de um ser humano para processar as informações, mas sim da tomada de decisões baseadas em respostas fornecidas por meio da análise dessas mesmas informações feita por uma RNA (CHOUDHURY; SEN, 2017).

Na literatura, principalmente nos últimos 10 anos, podemos ver um crescente aumento de estudos feitos com RNAs, quanto ao tema de previsão de mercado de ações, como em Choudhury e Sen, em 2017 (CHOUDHURY; SEN, 2017) onde a viabilidade das redes neurais artificiais é comparada com outras técnicas e tecnologias de previsão. E em Mohanty, Vijay e Gopakumar, em 2022 (MOHANTY; VIJAY; GOPAKUMAR, 2022) onde um programa que usa a previsão feita por RNAs executa estratégias de compra e venda, com desempenho acima de muitos fundos de investimento presentes no mercado. Além disso temos em Canillas no ano de 2021 (CANILLAS, 2021) a maior inspiração para a elaboração deste trabalho, porém no lugar de se fazer um estudo do mercado de ações espanhol, aqui se propõe um estudo da capacidade de previsão de uma RNA para o ativo BOVA 11 (YAHOO FINANCE, 2022), um ativo bolsista que reflete o comportamento da bolsa de ações brasileira

como um todo. Essa análise de capacidade é feita levando em conta o período pandêmico dos últimos anos, buscando estudar a série histórica de forma segmentada para melhor performance.

1.1 OBJETIVO

Este trabalho tem como objetivo estudar a viabilidade do uso de uma RNA, do tipo *MLP (multi-layer perceptron)* com arquitetura *feedforward* e treinamento via *backpropagation* para a previsão do valor de fechamento do dia seguinte do ativo bolsista brasileiro BOVA 11 (YAHOO FINANCE, 2022), em diferentes períodos da série histórica que se inicia em dezembro de 2008, levando em conta as tendências diferentes de cada período dessa série, principalmente os períodos que abrangem antes, durante e depois do pico da pandemia de *COVID19* dos últimos anos.

A proposta é separar a série em períodos, com tendências de comportamento, bem definidos, para fazer com que a rede consiga prever com maior precisão o valor de fechamento do dia seguinte aos dados de entrada da rede, além disso também será levado em conta a adição de variáveis que discriminam entre dias úteis e dias da semana, visando uma melhora na performance da rede.

1.2 ORGANIZAÇÃO DO TRABALHO

Este trabalho foi dividido em 6 capítulos, organizados da seguinte forma:

No capítulo 1 tem-se uma breve introdução sobre como e porque foram buscadas, formas de previsão do comportamento do mercado de ações, o que afeta esse mercado, as razões pelo qual as RNAs são escolhidas para fazer previsões nesse mercado, breve citação de alguns artigos e trabalhos correlatos ao tema e como eles serviram de inspiração para a construção do estudo proposto nesse trabalho.

No capítulo 2 é feita uma breve revisão sobre o setor de ações, seu comportamento e alguns exemplos da bibliografia de previsão nesse setor.

No capítulo 3 são apresentados o modelo biológico de neurônio e sua aproximação no modelo artificial, a estrutura de uma RNA, o treinamento utilizado nesse trabalho e alguns exemplos da bibliografia de previsão do setor de ações com RNAs.

No capítulo 4 são apresentados a metodologia, ambiente de estudo e divisão dos cenários propostos.

No capítulo 5 é apresentado o resultado comparativo entre os cenários propostos.

Por fim no capítulo 6 é apresentada a conclusão deste trabalho.

2 SETOR DE AÇÕES

2.1 BOVA 11

O ativo denominado BOVA11 se refere a um fundo que busca imitar o comportamento do índice BOVESPA, sem levar em conta deduções por taxas e despesas atreladas ao índice, por possuir essa característica de imitar a performance do índice BOVESPA em si, esse fundo não busca necessariamente performance no quesito aumento de capital, mas sim uma maneira de investidores poderem investir num espelho do índice BOVESPA como um todo (BLACKROCK, 2022).

Qualquer tipo de receita recebida por esse fundo devido sua natureza de espelhamento, não é repassada aos investidores, mas sim utilizada para aplicação e crescimento do próprio fundo, visando uma melhor performance em replicar o índice BOVESPA (BLACKROCK, 2022).

2.2 BANCO CENTRAL

O Banco Central do Brasil, é uma instituição financeira estatal, que tem como principal responsabilidade centralizar e assegurar o sistema financeiro do Brasil, como instituição o Banco Central do Brasil foi criado pela lei nº 4.595, de 1964, sendo uma instituição independente de qualquer ministério (BANCO CENTRAL DO BRASIL, 2022).

Dentre as responsabilidades do Banco Central, temos desde a fiscalização das instituições financeiras públicas e privadas do Brasil, sendo que ele se comporta como um banco dos bancos, onde todas as instituições financeiras no país devem manter contas, age também como emissor do dinheiro em espécie em circulação no Brasil, levando também a responsabilidade de controlar a inflação e as taxas de câmbio do país, forma essa de controle que interfere indiretamente com o mercado de ações brasileiro (BANCO CENTRAL DO BRASIL, 2022).

2.3 MERCADO DE AÇÕES

O mercado de ações é um segmento do mercado de capitais brasileiro onde empresas fazem a negociação de ações, que são títulos de renda variável que representam a menor parcela do capital social de uma empresa. Uma empresa inicia

a negociação de suas ações por meio de um *IPO* (*initial public offer* ou oferta pública inicial), onde essa empresa faz a venda de uma parte de si mesma, buscando financiamento de investidores sejam eles pessoas físicas ou jurídicas (BANCO DO BRASIL, 2022).

Com o tempo essa empresa necessita vender mais partes de si mesma em forma de ações para captar ainda mais investimento. Nesse cenário entra a questão da valorização das ações da empresa desde seu *IPO*, essa valorização permite que a empresa faça uma venda de uma quantidade menor de ações para captar uma quantidade de investimento igual ou até mesmo maior que seu *IPO*, por isso que o valor de mercado listado na bolsa é tão importante, pois representa uma das muitas ferramentas de financiamento utilizada por empresas de diferentes negócios (BANCO DO BRASIL, 2022).

Dentre as ações existem dois tipos principais, as ordinárias, que caracterizam ações com direito a votos nas assembleias de acionistas e as preferenciais que são ações que tem a preferência no recebimento dos dividendos distribuídos pelas empresas em períodos determinados pelas assembleias acionárias (BANCO DO BRASIL, 2022).

2.4 COMPORTAMENTO DAS AÇÕES

As ações se comportam como séries temporais financeiras e esse tipo de série tem algumas características comuns a ela, como a presença de tendências, sejam de altas ou de quedas. Essas tendências acontecem por uma gama de fatores, que englobam desde questões políticas nacionais e internacionais (MOHANTY; VIJAY; GOPAKUMAR, 2022).

Além de apresentar tendências, esse tipo de série apresenta um aspecto de sazonalidade, no qual épocas do período observado da série, apresentam um comportamento padrão que se repete sempre que as condições sazonais ocorrem, um exemplo disso seria o período de eleições, onde o mercado acaba se tornando extremamente volátil devido as possíveis complicações políticas que possam surgir desse período, outro ponto interessante a se notar, é a presença de valores incomuns que fogem do padrão da série, esse pontos tem como característica principal um retorno gradual ao padrão demonstrado pela série. Todos esses pontos levam a série a possuir um comportamento não-linear (MOHANTY; VIJAY; GOPAKUMAR, 2022).

Existem variáveis que afetam o comportamento das ações, nesse trabalho, foi abordado algumas dessas variáveis, de forma a tentar prever o comportamento do valor da ação ao final de cada dia, essas variáveis e como elas afetam o valor da ação estão expostas a seguir (YAHOO FINANCE, 2022):

- a) “Data”: a data em si na análise da ação, traz consigo as questões de sazonalidade e tendências de períodos específicos, que levam a alteração no comportamento da série histórica;
- b) “Valor de abertura” e “valor de fechamento”: os valores de abertura e fechamento da ação no dia analisado, pode afetar diretamente o comportamento da ação no dia em questão, pois pode levar à uma repetição da tendência associada ao valor de fechamento do dia anterior;
- c) “Valor máximo” e “valor mínimo”: o valor máximo atingindo pela ação, mostra por exemplo, o comportamento da tendência no dia em questão, esse valor se muito alto e fora do padrão observado ao longo do dia, traz um pico que pode muitas vezes levar a uma venda de ativos em massa, levando à uma subsequente queda do valor da ação, o valor mínimo atingido pela ação apresenta influência similar, porém no sentido inverso;
- d) “Valor de fechamento ajustado”: quando se tem um valor de fechamento ajustado diferente do valor de fechamento atingindo no dia, temos uma influência direta no dia seguinte, pois nesse tipo de situação, pode haver uma valorização ou desvalorização, não esperada pelo mercado, num momento em que o mesmo já estava fechado, levando a venda ou compra de forma diferente do que seria se o valor de fechamento normal tivesse sido mantido;
- e) “Volume transacionado”: o volume de ações transacionadas num dia, tem influência direta no valor da ação, pois com um alto volume, reflete um aumento na oferta de ações disponíveis ao longo do dia, com o aumento da oferta temos por consequência uma queda no valor da ação;
- f) “Dia da semana”: o dia da semana em que as transações de uma ação estão ocorrendo também influencia o comportamento da ação, temos como exemplo dias como sexta e segunda, respectivamente o último e o primeiro dia da semana quando ocorre a abertura do mercado. No caso do último dia, pode levar a um comportamento mais agressivo de uma tendência observada nos outros dias da semana, devido a pausa que virá com o final de semana, o mesmo ocorre no caso

do primeiro dia da semana, onde uma tendência pode vir a cessar, devido a pausa do final de semana.

Além dessas variáveis, existem outras que não foram abordadas nesse trabalho que influenciam o comportamento do mercado de ações, como por exemplo a taxa Selic, a taxa básica de juros que rege a economia do Brasil. Com valores altos dessa taxa temos um aumento dos investimentos em renda fixa, levando a um esvaziamento do mercado de ações, a diminuição dessa taxa leva a um efeito contrário.

2.5 PREVISÃO NO MERCADO DE AÇÕES

A busca pela previsão no mercado financeiro e por consequência, no mercado de ações, existe desde a sua concepção e tentar encontrar padrões naquilo que afeta monetariamente uma população sempre foi um grande desafio. Na última década modelos de previsão e decisão com base em modelagem e algoritmos, se tornaram viáveis no mercado de ações, surgindo assim os fundos de investimento com gestão quantitativa (CANILLAS, 2021).

Na literatura pesquisada, para a elaboração desse trabalho, a previsão de valores de ações e ativos presentes em diferentes bolsas de valores, só foi observada, em previsões de dia seguinte, isso é a previsão só é feita a fim de prever o valor para o dia seguinte dos dados de entrada, não foi observada a previsão para casos de períodos maiores que um dia, provavelmente devido ao caráter volátil desse tipo de série histórica.

Gestão quantitativa pode ser definida por uma tomada de decisão num fundo de investimentos, baseada em previsões feita por algoritmos, alimentados por uma modelagem definida por uma equipe técnica multidisciplinar, esse tipo de fundo vai de via contrária ao que é visto majoritariamente no mercado de ações, onde a experiência e discernimento da equipe gestora é o que define a estratégia, atualmente é possível citar como maior referência no mercado a *Kadima Asset Management* (KADIMA, 2022) quando o assunto é gestão quantitativa, lembrando que apesar das previsões fornecidas por esses algoritmos, eles servem como uma consulta para que as decisões da gestão desse tipo de fundo não seja feita baseada puramente na intuição e experiência de um ser humano (KADIMA, 2022).

Em Kaupa, em 2013 (KAUPA, 2013) se vê um exemplo do uso de previsão de ações, onde a utilização de redes neurais do tipo MLP associado a modelos de gerenciamento de risco, visando a seleção de ações para investimento trouxe resultados positivos quando comparados com o índice BOVESPA. Em Torres, em 2021 (TORRES, 2021) se tem um estudo da previsão de diferentes ações brasileiras utilizando redes neurais do tipo LSTM(*long short term memory* ou memória de curto prazo longa) e GRU (*gated recurrent unit* ou unidade recorrente fechada) para previsão de valores de fechamento, nesse estudo é visto como diferentes redes neurais apresentam desempenho diferente para horizontes de tempo diferente, além disso em Canillas, em 2021 (CANILLAS, 2021) também se tem o uso de diferentes arquiteturas de rede neural para previsão, porém abordando o mercado espanhol prevendo valores de fechamento do dia seguinte do ativo IBEX 35.


3 REDES NEURAIS ARTIFICIAIS

Em 1943 McCulloch e Pitts apresentaram o neurônio artificial, esse tipo de concepção foi motivado pela ideia que a forma que o cérebro humano reconhece padrões é completamente diferente da forma convencional de funcionamento dos computadores digitais. O primeiro modelo de RNA, surgiu como o modelo supervisionado *Perceptron* desenvolvido por Rosenblatt em 1958 com o algoritmo para ajuste dos parâmetros livres dessa rede também publicado entre 1958 e 1962 por Rosenblatt (HAYKIN, 2009).

3.1 MODELO BIOLÓGICO E MODELO ARTIFICIAL

Com inspiração no modelo biológico de neurônio representado pela Figura 1, o modelo artificial de neurônio foi idealizado para resolução de problemas de uma forma diferente da tradicional adotada por computadores até então, é importante ressaltar que o neurônio artificial exemplificado, na Figura 2, não está nem perto do neurônio biológico, ainda assim é o mais próximo de recriar ao nível de hierarquia computacional encontrado no modelo biológico (HAYKIN, 2009).


Figura 1 – Neurônio biológico.



Fonte: Adaptado de (HAYKIN, 2009).

Os neurônios artificiais que foram construídos, apesar de primitivos, trouxeram um aumento ao nível de entendimento que temos das RNAs e suas aplicações vem crescendo ano após ano, com o aumento do poder computacional que foi experimentado nas últimas décadas. O modelo descrito a seguir na Figura 2 ilustra o neurônio artificial, seguido de sua descrição matemática.

Figura 2 – Neurônio artificial.



Fonte: Adaptado de (HAYKIN, 2009).

Uma RNA pode ser dividida em três elementos básicos e um *bias* (HAYKIN, 2009):

- Um conjunto de sinapses, com característica de ter um peso próprio, os sinais de entrada x_i são conectados aos neurônios k e multiplicados pelo peso w_{ki} ;
- Um somador agindo como um combinador linear, de forma a somar os sinais de entrada após a multiplicação pelos pesos sinápticos;
- Uma função de ativação, utilizada para limitar a amplitude da saída do neurônio, comumente limitando o intervalo de valor entre $[0,1]$ ou $[-1,1]$;
- Um bias externo, representado por b_k , com função de aumentar ou diminuir a entrada da função de ativação, variando conforme seu sinal sendo positivo ou negativo.

A descrição matemática de um neurônio artificial é apresentada nas equações 1 e 2 a seguir:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (1)$$


$$y_k = F(s) * (u_k + b_k) \quad (2)$$

Sendo:

- u_k : saída linear do neurônio k ;
- $[w_{k1}, w_{k2}, w_{k3}, \dots, w_{km}]$: pesos sinápticos do neurônio k ;
- $[x_1, x_2, x_3, \dots, x_m]$: sinais de entrada;
- y_k : sinal de saída não linear do neurônio k ;
- $F(s)$: função de ativação;
- b_k : peso bias.


Quanto a função de ativação, a seguir temos os tipos básicos de função de ativação usualmente utilizados (KROSE; SMAGT, 1996):

Figura 3 – Função relé.




Fonte: Adaptado de (KROSE; SMAGT, 1996).

Figura 4 – Função lógica threshold.



Fonte: Adaptado de (KROSE; SMAGT, 1996).

Figura 5 – Função sigmoide.



Fonte: Adaptado de (KROSE; SMAGT, 1996).

3.2 ARQUITETURA DA RNA

A forma em que os neurônios de uma RNA, são conectados é diretamente ligada ao tipo de algoritmo de aprendizado utilizado para treinar a rede, fundamentalmente dividimos em dois tipos de arquitetura de rede neural, as redes *feedforward* e as redes recorrentes (HAYKIN, 2009). A rede *feedforward* se distingue pela sua organização em camadas, com camadas de entrada, ocultas (em caso de múltiplas camadas) e camada de saída, sem nenhum tipo de realimentação entre camadas, a rede do tipo recorrente se distingue da rede *feedforward* pois possui ao menos, uma repetição de realimentação entre as camadas de saída e as camadas anteriores (HAYKIN, 2009).

3.3 TIPOS DE TREINAMENTO DAS REDES NEURAIS ARTIFICIAIS

Os tipos de treinamento podem ser separados em dois básicos e um tipo híbrido entre eles:

- a) Treinamento supervisionado: é um tipo de treinamento onde a rede, é treinada a partir de sinais de entrada e saídas esperadas fornecidos por um “professor” externo (KROSE; SMAGT, 1996);
- b) Treinamento não-supervisionado: é um tipo de treinamento onde a unidade de saída é treinada para condizer com conjuntos padrões encontrados nos sinais de entrada, nesse tipo de treinamento o sistema espera encontrar padrões estatisticamente distintos presentes na base de entrada (KROSE; SMAGT, 1996);
- c) Treinamento híbrido: se baseia na alternância dos dois treinamentos anteriores.

3.4 TREINAMENTO DO TIPO *BACKPROPAGATION*

O Treinamento do tipo *Backpropagation* foi proposto por Werbos em 1974, é um tipo de treinamento separado por 3 passos distintos, o primeiro passo é o estágio de *feedforward* do padrão de entrada, que irá produzir uma saída, o segundo passo se trata da determinação do erro, que é calculado propagando no sentido inverso ao da entrada, por meio da derivada parcial do erro quadrático de cada elemento, e o terceiro passo consiste do ajuste dos pesos de cada um dos elementos, assim um novo padrão é gerado e o processo é repetido, visando a convergência (WERBOS, 1974).

Temos a seguir a equação 3 que fornece a soma do erro quadrático de cada neurônio alocado na camada de saída da rede:

$$\varepsilon^2 = \sum_{i=1}^{ns} \varepsilon_i^2 \quad (3)$$

Sendo:

- ε^2 : erro quadrático.
- $\varepsilon_i = d_i - y_i$;
- d_i : A saída real do elemento i da camada de saída;

- y_i : A saída calculada do elemento i da camada de saída;
- ns : Número de neurônios da camada de saída.

Com isso, adotando o neurônio de índice i da rede, com a utilização do método do gradiente descendente, os pesos serão ajustados de acordo com a equação 4 a seguir (HAYKIN, 2009):

$$U_i(k + 1) = U_i(k) + \Delta U_i(k) \quad (4)$$

Sendo:

- $\Delta U_i(k)$: $-\alpha[\nabla_i(k)]$;
- α : taxa de aprendizado;
- $\nabla_i(k)$: gradiente do erro quadrático com relação aos pesos do neurônio i avaliado na camada;
- $U_i(k + 1)$: vetor contendo os pesos do neurônio i atualizados
- $U_i(k)$: vetor contendo os pesos do neurônio i da iteração atual;
- k : número representando à iteração atual.

3.5 USO DE REDES NEURAIIS PARA PREVISÃO DE VALORES DE AÇÃO

A previsão de valores de ação é uma prática já feita no mercado, assim o uso desse tipo de previsão como ferramenta de auxílio a decisão de compra ou venda foi estudada, principalmente as técnicas utilizadas para realizar esse tipo de previsão. Tem-se como exemplo das técnicas utilizadas métodos de análise técnica, análise fundamental, análise de série temporal e algumas outras técnicas de aprendizado de máquina além das RNAs para realizar esse tipo de previsão, porém nenhum desses métodos se provou consistentemente aceitável como o uso de RNAs (CLOUDHURY; SEM, 2017). Um grande exemplo da eficácia do uso de redes neurais artificiais, para previsão e tomada de decisões, no mercado de ações está em (MOHANTY; VIJAY; GOPAKUMAR, 2022) onde um *stockbot* (programa responsável por comprar e vender ações) que utiliza da previsão do mercado de ações por meio de RNAs foi capaz de se planejar a frente do mercado e atingir ganhos 15 vezes superiores aos *ETFs*

(*exchange trade funds* ou fundos de investimento bolsistas) mais agressivos do mercado.

4 METODOLOGIA E AMBIENTE DE ESTUDO

Neste capítulo será elaborado toda a estrutura, parâmetros e conceitos adotados para ser realizada a previsão dos preços da ação BOVA 11 (*Yahoo Finance*, 2022) bem como a separação da base de dados para treinamento e teste da rede neural. A base de dados tem que ser preparada para a previsão diária do preço de fechamento do ativo, sendo a preparação diferente para os diferentes cenários testados.

4.1 ANÁLISE DA BASE DE DADOS E AMBIENTE DE ESTUDO

Foi coletado todo o histórico do ativo BOVA 11 (*Yahoo Finance*, 2022), o período abrangido sendo de 5 de dezembro de 2008 até 14 de outubro de 2022, esse período está ilustrado na Figura 6 a seguir. No eixo das abcissas temos a representação do período de tempo abrangido iniciando em 2008 e terminando em 2022, devido ao grande volume de dados a escala está separada em anos para melhor visualização. No eixo das ordenadas temos o valor em reais da ação nos seus diferentes pontos, a escala abrangendo de 40 reais até 120 reais para melhor visualização; além disso temos uma linha de tendencia em vermelho para facilitar a análise.

Figura 6 – Histórico de valor do ativo BOVA 11 no período de 2008 à 2022.



Fonte: Elaborado pelo autor.

Esse é o primeiro conjunto de base de dados selecionado na série histórica da ação, esse conjunto será testado em todas as variações e cenários apresentados nesse trabalho.

Percebe-se nessa série histórica, períodos específicos onde a tendência do gráfico apresenta uma diferença significativa, a primeira divisão que pode ser feita está no período de 2008 à 2016 e no período de 2016 à 2022, com a separação nesses dois períodos pode-se visualizar uma evidente diferença na tendência de preços da ação como ilustrado nas Figura 7 e Figura 8 a seguir:

Figura 7 – Histórico da ação BOVA 11 no período de 2008 à 2016.



Fonte: Elaborado pelo autor.

Esse é o próximo conjunto de base de dados selecionado na série histórica da ação, esse conjunto será testado em todas as variações e cenários apresentados nesse trabalho.

Figura 8 – Histórico da ação BOVA 11 no período de 2016 à 2022.



Fonte: Elaborado pelo autor.

Esse é o próximo conjunto de base de dados selecionado na série histórica da ação, esse conjunto será testado em todas as variações e cenários apresentados nesse trabalho.

Percebe-se um comportamento atípico de queda no período de 2016 à 2022 no ano de 2020 devido a pandemia de COVID-19 que levou a paradas bruscas de emergência na bolsa de valores brasileira devido à queda descontrolada dos valores, pode-se então ser feita mais uma distinção na base de dados para checar como esse período vai afetar o treinamento da rede neural, separou-se então o período a partir do começo do efeito pandêmico na bolsa de valores, período esse abrangendo do dia 1 de abril de 2020 até o dia 14 de outubro de 2022, para efeitos de comparação também foi separado o período a partir de 1 de agosto de 2020, devido a estabilização do comportamento da bolsa de valores a partir dessa data. Ambos esses períodos são demonstrados nas Figura 9 e Figura 10 a seguir.

Figura 9 – Histórico da ação BOVA 11 no período a partir de abril de 2020.



Fonte: Elaborado pelo autor.

Esse é o próximo conjunto de base de dados selecionado na série histórica da ação, esse conjunto será testado em todas as variações e cenários apresentados nesse trabalho.

Figura 10 – Histórico da ação BOVA 11 no período a partir de agosto de 2020.



Fonte: Elaborado pelo autor.


Percebe-se que removendo o período de alta instabilidade causado pela pandemia da série histórica a linha de tendência tende a uma certa estabilidade.

Esse é o próximo conjunto de base de dados selecionado na série histórica da ação, esse conjunto será testado em todas as variações e cenários apresentados nesse trabalho.

4.2 CENÁRIO 1

Nesse primeiro cenário, o fluxo de execução é descrito na Figura 11 a seguir:

Figura 11 – Fluxo de execução do cenário 1.



Fonte: Elaborado pelo autor.

4.2.1 Definição dos padrões de entrada

Os dados da ação BOVA 11 foram extraídos do *Yahoo Finance*. Sua integração por meio de uma biblioteca e API (interface de aplicação programável) específica de fácil uso via *Python* permite acessar todo o histórico da ação, esses dados sem nenhum tratamento, vem separados em colunas, descritos a seguir: “Data”, “Valor de abertura”, “Valor máximo”, “Valor mínimo”, “Valor de fechamento”, “Valor de fechamento ajustado” e “Volume”.

Temos na Tabela 1 a seguir uma amostra dos dados da tabela exemplificação como esses dados são fornecidos sem nenhum tipo de tratamento:

Tabela 1 – Amostra dos dados da ação BOVA 11 retirados do *Yahoo Finance*.

Data	Valor de abertura	Valor máximo	Valor mínimo	Valor de fechamento	Valor de fechamento ajustado	Volume
05/01/2009	40,2	42	39,7	42	42	341700
06/01/2009	42,06	42,32	41,55	42,32	42,3199997	178300
07/01/2009	41,75	41,77	40,45	40,64	40,6399994	73400
08/01/2009	40,15	42,2	40,15	42,2	42,2000008	195300
09/01/2009	41,98	42,47	41,16	42	42	271900

Fonte: *Yahoo Finance*, 2022.

4.2.2 Preenchimento dos dados faltantes

Em caso de espaços vazios na base de dados, foi utilizada a função “ffill” (função que preenche a célula com o valor da célula da linha anterior caso a célula esteja vazia) e “bfill” (função que preenche a célula com o valor da célula da linha seguinte caso a célula esteja vazia) inerentes ao *Python*.

4.2.3 Adequação da base de dados

Como a base vem com uma coluna de data, formato esse que não é aceito diretamente como entrada da rede neural, é feita a separação desses dados utilizando

funções inerentes do *Python* que separam a coluna “Data” em colunas “Dia”, “Mês”, “Ano”. A seguir temos uma amostra que demonstra o novo formato da base de dados:

Tabela 2 – Amostra dos dados da ação BOVA 11 retirados do *Yahoo Finance*.

Dia	Mês	Ano	Valor de abertura	Valor máximo	Valor mínimo	Valor de fechamento	Valor de fechamento ajustado	Volume
5	1	2009	40,2	42	39,7	42	42	341700
6	1	2009	42,06	42,32	41,55	42,32	42,3199997	178300
7	1	2009	41,75	41,77	40,45	40,64	40,6399994	73400
8	1	2009	40,15	42,2	40,15	42,2	42,2000008	195300
9	1	2009	41,98	42,47	41,16	42	42	271900

Fonte: *Yahoo Finance*, 2022.

4.2.4 Criação dos padrões de entrada e saída

O conjunto de entradas da rede neural foi composto pelas seguintes variáveis:

- “Dia”: [1...31] fornece a informação do dia;
- “Mês”: [1...12] fornece a informação do mês;
- “Ano”: [Exemplo: 2009] fornece a informação do ano;
- “Valor de abertura” (d): fornece o valor em reais inicial da ação ao início da cotação do dia, esse valor corresponde ao valor de fechamento do dia anterior;
- “Valor máximo” (d): fornece o valor em reais máximo atingindo pela ação na cotação daquele dia;
- “Valor mínimo” (d): fornece o valor em reais mínimo atingindo pela ação na cotação daquele dia;
- “Valor de fechamento” (d): fornece o valor em reais atingido ao final da cotação referente ao dia atual;
- “Valor de fechamento ajustado” (d): fornece o valor em reais de fechamento ajustado que se trata do valor quando uma ação, dentro de qualquer dia de negociação, tem o seu preço alterado para incluir quaisquer distribuições de proventos e ações corporativas que ocorreram em qualquer momento antes da abertura do dia seguinte;
- “Volume” (d): fornece o número de ações negociadas no dia inteiro de cotação.

O conjunto de saída da rede neural é dado por:

- a) “Valor de fechamento do dia seguinte” ($d+1$): valor em reais do fechamento do dia seguinte.

4.2.5 Normalização dos dados

Para o uso adequado da biblioteca de redes neurais escolhida neste trabalho, foi necessário o uso de normalização dos dados, essa mesma biblioteca possui uma função recomendada que foi utilizada para realizar essa normalização, estabelecendo valores entre -1 e 1 para os dados.

4.2.6 Criação dos conjuntos de treinamento e teste

Neste trabalho, foram usadas algumas variações de período da base de dados, devido as oscilações da série histórica da ação, houve testes com períodos específicos, porém todas os testes foram executados utilizando 70% da base como conjunto de treinamento e os 30% restantes como base de teste, essa separação ocorreu independentemente do tamanho da base. Segue a tabela com os conjuntos:

Tabela 3 – Conjunto dos dados da ação BOVA 11 para o cenário 1.

Conjunto	Treinamento		Teste	
	Entrada	Saída	Entrada	Saída
2008 à 2022	9 X 3542	1 X 3542	9 X 1518	1 X 1518
2008 à 2016	9 X 1820	1 X 1820	9 X 781	1 X 781
2016 à 2022	9 X 1720	1 X 1720	9 X 738	1 X 738
04/2020 à 2022	9 X 647	1 X 647	9 X 278	1 X 278
08/2020 à 2022	9 X 562	1 X 562	9 X 241	1 X 241


Fonte: Elaborado pelo autor.

4.2.7 Configuração da RNA

A RNA foi testada em dois formatos diferentes para esse cenário, um formato utilizando 1 camada oculta, e outro formato utilizando 2 camadas ocultas.

No primeiro formato se tem 8 neurônios na camada de entrada, 17 neurônios na camada oculta e 1 neurônio na camada de saída, função de ativação do tipo logística sigmoide presente na equação 5, número de iterações máximas de $5 * 10^8$ e taxa de aprendizado de $1 * 10^{-3}$ ambas sendo sugestões dadas pela biblioteca utilizada no *python*. Essa configuração pode ser demonstrada na Figura 12:

Figura 12 – Diagrama da rede neural com a configuração de uma camada oculta.



Fonte: Elaborado pelo autor.

A equação da logística sigmoide pode ser demonstrada na equação a seguir:


$$f(x) = \frac{(1)}{(1+e^{-\lambda * x})} \quad (5)$$

Sendo:

- λ : inclinação da curva.

No segundo formato se tem 8 neurônios na camada de entrada, 17 neurônios na primeira camada oculta, 8 neurônios na segunda camada oculta e 1 neurônio na camada de saída, função de ativação do tipo logística sigmoide (Equação 5), número de iterações máximas de $5 * 10^8$, taxa de aprendizado de $1 * 10^{-3}$. Essa configuração pode ser demonstrada na Figura 13:

Figura 13 – Diagrama da rede neural com a configuração de duas camadas ocultas.



Fonte: Elaborado pelo autor.

4.3 CENÁRIO 2, 3 E 4

Os cenários 2, 3 e 4 possuem a mesma construção do cenário 1, porém com a adição de uma ou duas variáveis de entrada. No cenário 2 tem-se a adição da variável dia útil, que diferencia entre dias que a bolsa de valores opera ou não, representado por -1 e 1 respectivamente; no cenário 3 tem-se a adição da variável dia da semana, que diferencia os dias da semana de domingo a sexta-feira representados por 0 a 6 respectivamente. No cenário 4 ambas as variáveis dia útil e dia da semana são adicionadas.

4.4 AVALIAÇÃO DO DESEMPENHO DA PREVISÃO

Para medir-se o desempenho da rede neural foi utilizado duas métricas diferentes, o erro absoluto percentual médio (*Mean Absolute Percentual Error* ou *MAPE*) (PARK et al., 1991), uma métrica já conhecida e muito utilizada para medir os desempenhos de redes neurais e o erro direcional médio (*Mean Directional Error* ou *MDA*) (TORRES, 2021), que se trata da média de acerto direcional da previsão, essa métrica é utilizada em previsões do mercado financeiro encontradas na literatura, diferente do *MAPE* que mostra o erro percentual absoluto da previsão o *MDA* analisa apenas se a previsão acerta a direção tomada pela ação. O *MDA* acaba trazendo uma métrica mais pertinente da previsão de ações, pois quando a rede é utilizada como guia para compra ou venda de ações, saber se haverá uma queda ou um aumento do preço é mais importante do que saber a variação de preço em si (TORRES, 2021).

Uma boa forma de exemplificar a importância do *MDA* seria o seguinte caso: tem-se uma ação de valor 100, a rede prevê o valor para o dia seguinte de 99.5, porém no outro dia temos o valor de 100.5, o erro absoluto da rede é de 0.99%, porém tomando a previsão como base e tendo a venda da ação sido feita pois a previsão indicou uma queda no dia seguinte, haveria uma perda de valor, pois caso a compra de mais ativos tivesse sido feita se teria um ganho de 0.5% do valor investido e valorização de 0.5% do valor em ação que já tínhamos anteriormente.

O *MAPE* e o *MDA* são expressos nas seguintes equações:

$$MAPE = \frac{1}{NA} * \sum_{d=1}^{NA} \left| \frac{y_{alvo}(d) - y_{previsto}(d)}{y_{alvo}(d)} \right| * 100 \quad (6)$$

- *MAPE* : Mean Absolute Percent Error (percentual do erro absoluto médio).
- *NA* : número da amostragem da série de tempo discreto;
- $y_{alvo}(d)$: valor alvo referente ao dia d;
- $y_{previsto}(d)$: valor previsto pela rede referente ao dia d.

$$MDA = \frac{1}{NA} \sum_t 1 \text{ sign}(X_t - X_{t-1}) == \text{sign}(F_t - X_{t-1}) \quad (7)$$

- *MDA* : Mean directional accuracy (media de acerto direcional);
- *NA* : número da amostragem da série de tempo discreto;
- X_t : o valor real observado na série de tempo discreto;
- F_t : o valor previsto ou estimado;
- *sign* : função sinal;
- 1: uma função indicadora;

Um valor de *MDA* superior a 50% seria o suficiente para ser considerado uma boa performance, pois acertaria a direção da ação mais da metade das vezes, possibilitando uma tomada de decisão de compra ou venda de ativo mais assertiva (TORRES, 2021).

5 RESULTADOS E DISCUSSÕES.

Nos resultados foram tratados os diferentes cenários propostos na metodologia, cada um dos cenários possui 2 variações de estrutura com 1 ou 2 camadas ocultas, com 5 conjuntos de dados diferentes referentes a 5 períodos da série histórica da ação BOVA11 (*Yahoo Finance*, 2022), assim nos resultados foram apresentados 40 testes diferentes com suas respectivas análises de *MAPE* e *MDA*, além do tempo de processamento de máquina exigido em cada teste.


Cada teste foi exposto de forma gráfica comparativa entre o valor previsto de fechamento e o valor real, utilizando a ferramenta *Power Bi* para a visualização.

5.1 CENÁRIO 1

5.1.1 Formato com uma camada oculta

A seguir se tem os gráficos referentes ao teste do cenário 1.

Figura 14 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2022.



Fonte: Elaborado pelo autor.

Figura 15 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2016.




Fonte: Elaborado pelo autor.

Figura 16 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2016 à 2022.




Fonte: Elaborado pelo autor.

Figura 17– Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 04/2020 à 2022.



Fonte: Elaborado pelo autor.

Figura 18 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 08/2020 à 2022.



Fonte: Elaborado pelo autor.

Com os resultados referentes a cada um desses gráficos, foi feita a Tabela 4 a seguir, que além de exibir os valores de desempenho, também permite fazer o comparativo entre os resultados.

Tabela 4 – Resultados agregados para o formato de uma camada oculta do cenário 1.

Treinamento	MAPE	MDA
Com o período total (até o dia 14/10/2022)	21,73%	46,85%
2008 à 2016	1,56%	53,22%
2016 à 2022	7,98%	47,12%
04/2020 à 2022	3,00%	46,56%
08/2020 à 2022	1,87%	52,44%

Fonte: Elaborado pelo autor.

Analisando a tabela é perceptível que o melhor resultado para todos os critérios selecionados foi observado na RNA treinada no período de 2008 à 2016.

5.1.2 Formato com duas camadas ocultas

A seguir se tem os gráficos referentes ao teste do cenário 1, utilizando o formato com duas camadas ocultas, sendo treinado e testado nos mesmos moldes do caso anterior.

Figura 19 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2022.



Fonte: Elaborado pelo autor.

Figura 20 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2016.




Fonte: Elaborado pelo autor.

Figura 21 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2016 à 2022.




Fonte: Elaborado pelo autor.

Figura 22 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 04/2020 à 2022.



Fonte: Elaborado pelo autor.

Figura 23 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 08/2020 à 2022.



Fonte: Elaborado pelo autor.

Com os resultados referentes a cada um desses gráficos, foi feita a Tabela 5 a seguir, que além de exibir os valores de desempenho, também permite fazer o comparativo entre os resultados.

Tabela 5 – Resultados agregados para o formato de duas camadas ocultas do cenário 1.

Treinamento	MAPE	MDA
Com o período total (até o dia 14/10/2022)	17,72%	47,14%
2008 à 2016	1,34%	52,65%
2016 à 2022	2,49%	49,30%
04/2020 à 2022	1,31%	48,15%
08/2020 à 2022	1,68%	50,61%

Fonte: Elaborado pelo autor.

Analisando a tabela é perceptível que o melhor resultado para o critério de *MAPE* está na RNA treinada com o período de 04/2020 à 2022, apesar de ser pequena a diferença quando comparado ao que foi observado na RNA treinada no período de


2008 à 2016, treinamento esse que obteve os melhores resultados para o critério de *MDA* e tempo de processamento.

5.2 CENÁRIO 2

5.2.1 Formato com uma camada oculta


A seguir se tem os gráficos referentes ao teste do cenário 2, utilizando o formato com uma camada oculta, sendo treinado e testado nos mesmos moldes do cenário anterior.

Figura 24 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2022.




Fonte: Elaborado pelo autor.

Figura 25 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2016.




Fonte: Elaborado pelo autor.

Figura 26 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2016 à 2022.




Fonte: Elaborado pelo autor.

Figura 27 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 04/2020 à 2022.



Fonte: Elaborado pelo autor.

Figura 28 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 08/2020 à 2022.



Fonte: Elaborado pelo autor.

Com os resultados referentes a cada um desses gráficos, foi feita a Tabela 6 a seguir, que além de exibir os valores de desempenho, também permite fazer o comparativo entre os resultados.

Tabela 6 – Resultados agregados para o formato de uma camada oculta do cenário 2.

Treinamento	MAPE	MDA
Com o período total (até o dia 14/10/2022)	19,78%	31,55%
2008 à 2016	1,31%	35,85%
2016 à 2022	6,01%	32,25%
04/2020 à 2022	4,04%	33,09%
08/2020 à 2022	2,24%	34,02%


Fonte: Elaborado pelo autor.

Analisando a tabela é perceptível que o melhor resultado para todos os critérios selecionados foi observado na RNA treinada no período de 2008 à 2016.

5.2.2 Formato com duas camadas ocultas


A seguir se tem os gráficos referentes ao teste do cenário 2, utilizando o formato com duas camadas ocultas, sendo treinado e testado nos mesmos moldes do caso anterior.

Figura 29 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2022.




Fonte: Elaborado pelo autor.

Figura 30 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2016.




Fonte: Elaborado pelo autor.

Figura 31 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2016 à 2022.




Fonte: Elaborado pelo autor.

Figura 32 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 04/2020 à 2022.



Fonte: Elaborado pelo autor.

Figura 33 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 08/2020 à 2022.



Fonte: Elaborado pelo autor.

Com os resultados referentes a cada um desses gráficos, foi feita a Tabela 7 a seguir, que além de exibir os valores de desempenho, também permite fazer o comparativo entre os resultados.

Tabela 7 – Resultados agregados para o formato de duas camadas ocultas do cenário 2.

Treinamento	MAPE	MDA
Com o período total (até o dia 14/10/2022)	16,73%	32,35%
2008 à 2016	0,98%	34,57%
2016 à 2022	1,96%	33,60%
04/2020 à 2022	1,06%	28,78%
08/2020 à 2022	1,02%	31,95%

Fonte: Elaborado pelo autor.


Analisando a tabela é perceptível que o melhor resultado para todos os critérios selecionados foi observado na RNA treinada no período de 2008 à 2016.

5.3 CENÁRIO 3

5.3.1 Formato com uma camada oculta


A seguir se tem os gráficos referentes ao teste do cenário 3, utilizando o formato com uma camada oculta, sendo treinado e testado nos mesmos moldes do cenário anterior.

Figura 34 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2022.




Fonte: Elaborado pelo autor.

Figura 35 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2016.




Fonte: Elaborado pelo autor.

Figura 36 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2016 à 2022.




Fonte: Elaborado pelo autor.

Figura 37 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 04/2020 à 2022.



Fonte: Elaborado pelo autor.

Figura 38 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 08/2020 à 2022.



Fonte: Elaborado pelo autor.

Com os resultados referentes a cada um desses gráficos, foi feita a Tabela 8 a seguir, que além de exibir os valores de desempenho, também permite fazer o comparativo entre os resultados.

Tabela 8 – Resultados agregados para o formato de uma camada oculta do cenário 3.

Treinamento	MAPE	MDA
Com o período total (até o dia 14/10/2022)	20,39%	47,04%
2008 à 2016	1,76%	53,60%
2016 à 2022	4,71%	47,32%
04/2020 à 2022	2,91%	46,03%
08/2020 à 2022	3,16%	46,34%


Fonte: Elaborado pelo autor.

Analisando a tabela é perceptível que o melhor resultado para todos os critérios selecionados foi observado na RNA treinada no período de 2008 à 2016.

5.3.2 Formato com duas camadas ocultas


A seguir se tem os gráficos referentes ao teste do cenário 3, utilizando o formato com duas camadas ocultas, sendo treinado e testado nos mesmos moldes do caso anterior.

Figura 39 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2022.




Fonte: Elaborado pelo autor.

Figura 40 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2016.




Fonte: Elaborado pelo autor.

Figura 41 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2016 à 2022.




Fonte: Elaborado pelo autor.

Figura 42 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 04/2020 à 2022.



Fonte: Elaborado pelo autor.

Figura 43 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 08/2020 à 2022.



Fonte: Elaborado pelo autor.

Com os resultados referentes a cada um desses gráficos, foi feita a Tabela 9 a seguir, que além de exibir os valores de desempenho, também permite fazer o comparativo entre os resultados.

Tabela 9 – Resultados agregados para o formato de duas camadas ocultas do cenário 3.

Treinamento	MAPE	MDA
Com o período total (até o dia 14/10/2022)	17,90%	47,53%
2008 à 2016	1,41%	49,24%
2016 à 2022	2,30%	50,50%
04/2020 à 2022	1,41%	50,79%
08/2020 à 2022	1,85%	45,12%

Fonte: Elaborado pelo autor.


Analisando a tabela é perceptível que o melhor resultado para todos os critérios selecionados foi observado na RNA treinada no período de 04/2020 à 2022 e quanto ao critério avaliando o *MAPE* o treinamento com o período de 2008 à 2016 atingiu um resultado tão bom quanto ao do período de 04/2020 à 2022.

5.4 CENÁRIO 4

5.4.1 Formato com uma camada oculta


A seguir se tem os gráficos referentes ao teste do cenário 4, utilizando o formato com uma camada oculta, sendo treinado e testado nos mesmos moldes do cenário anterior.

Figura 44 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2022.




Fonte: Elaborado pelo autor.

Figura 45 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2016.




Fonte: Elaborado pelo autor.

Figura 46 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2016 à 2022.




Fonte: Elaborado pelo autor.

Figura 47 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 04/2020 à 2022.



Fonte: Elaborado pelo autor.

Figura 48 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 08/2020 à 2022.



Fonte: Elaborado pelo autor.

Com os resultados referentes a cada um desses gráficos, foi feita a Tabela 10 a seguir, que além de exibir os valores de desempenho, também permite fazer o comparativo entre os resultados.

Tabela 10 – Resultados agregados para o formato de uma camada oculta do cenário 4.

Treinamento	MAPE	MDA
Com o período total (até o dia 14/10/2022)	21,55%	31,62%
2008 à 2016	1,66%	34,44%
2016 à 2022	5,11%	32,38%
04/2020 à 2022	3,95%	32,37%
08/2020 à 2022	1,85%	36,51%


Fonte: Elaborado pelo autor.

Analisando a tabela é perceptível que o melhor resultado para o critério de *MAPE* foi observado no período de 2008 à 2016, enquanto que o melhor resultado para o critério de *MDA* foi observado no período de 08/2020 à 2022, porém vale ressaltar que o *MDA* nesse formato e cenário de RNA pode ser considerado ruim pois está abaixo de 50% para todos os casos de treinamento.

5.4.2 Formato com duas camadas ocultas


A seguir se tem os gráficos referentes ao teste do cenário 4, utilizando o formato com duas camadas ocultas, sendo treinado e testado nos mesmos moldes do caso anterior.

Figura 49 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2022.




Fonte: Elaborado pelo autor.

Figura 50 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2008 à 2016.




Fonte: Elaborado pelo autor.

Figura 51 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 2016 à 2022.




Fonte: Elaborado pelo autor.

Figura 52 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 04/2020 à 2022.



Fonte: Elaborado pelo autor.

Figura 53 – Gráfico do teste comparativo entre a previsão da RNA e a realidade, treinamento com o período de 08/2020 à 2022.



Fonte: Elaborado pelo autor.

Com os resultados referentes a cada um desses gráficos, foi feita a Tabela 11 a seguir, que além de exibir os valores de desempenho, também permite fazer o comparativo entre os resultados.

Tabela 11 – Resultados agregados para o formato de duas camadas ocultas do cenário 4.

Treinamento	MAPE	MDA
Com o período total (até o dia 14/10/2022)	17,39%	32,02%
2008 à 2016	1,19%	34,70%
2016 à 2022	2,16%	34,15%
04/2020 à 2022	1,01%	31,29%
08/2020 à 2022	1,17%	31,95%

Fonte: Elaborado pelo autor.

Analisando a tabela é perceptível que o melhor resultado para o critérios de MDA foi observado na RNA treinada no período de 2008 à 2016 e quanto ao critério avaliando o MAPE o treinamento com o período de 04/2020 à 2022 atingiu o melhor resultado, porém vale ressaltar que o MDA nesse formato e cenário de RNA pode ser considerado ruim pois está abaixo de 50% para todos os casos de treinamento.

5.5 RESULTADOS COMPARATIVOS ENTRE OS CENÁRIOS

Para realizar um comparativo entre todos os cenários e formatos, foi feita a junção entre as tabelas de resultados anteriores, essa tabela mostra essas diferentes combinações e compara o melhor resultado para cada período. As tabelas a seguir mostram esses comparativos, sendo a Tabela 12 referente ao comparativo de *MAPE* e a Tabela 13 referente ao comparativo de *MDA*.

Tabela 12 – Resultados agregados considerando o *MAPE* para todos os cenários e formatos.

	Cenário							
	1		2		3		4	
	Uma camada oculta	Duas camadas ocultas	Uma camada oculta	Duas camadas ocultas	Uma camada oculta	Duas camadas ocultas	Uma camada oculta	Duas camadas ocultas
Treinamento								
2008 à 2022	21,73%	17,72%	19,78%	16,73%	20,39%	17,90%	21,55%	17,39%
2008 à 2016	1,56%	1,34%	1,31%	0,98%	1,76%	1,41%	1,66%	1,19%
2016 à 2022	7,98%	2,49%	6,01%	1,96%	4,71%	2,30%	5,11%	2,16%
04/2020 à 2022	3,00%	1,31%	4,04%	1,06%	2,91%	1,41%	3,95%	1,01%
08/2020 à 2022	1,87%	1,68%	2,24%	1,02%	3,16%	1,85%	1,85%	1,17%

Fonte: Elaborado pelo autor.

Quanto ao critério de *MAPE* o melhor resultado geral, para todos os períodos de treinamento, foi observado no cenário 2 com o formato de duas camadas ocultas, mesmo o melhor resultado para o período de 04/2020 à 2022 não tendo sido nesse formato, a diferença é muito pequena.

Tabela 13 – Resultados agregados considerando o *MDA* para todos os cenários e formatos.

Treinamento	Cenário							
	1		2		3		4	
	Uma camada oculta	Duas camadas ocultas	Uma camada oculta	Duas camadas ocultas	Uma camada oculta	Duas camadas ocultas	Uma camada oculta	Duas camadas ocultas
2008 à 2022	46,85%	47,14%	31,55%	32,35%	47,04%	47,53%	31,62%	32,02%
2008 à 2016	53,22%	52,65%	35,85%	34,57%	53,60%	49,24%	34,44%	34,70%
2016 à 2022	47,12%	49,30%	32,25%	33,60%	47,32%	50,50%	32,38%	34,15%
04/2020 à 2022	46,56%	48,15%	33,09%	28,78%	46,03%	50,79%	32,37%	31,29%
08/2020 à 2022	52,44%	50,61%	34,02%	31,95%	46,34%	45,12%	36,51%	31,95%

Fonte: Elaborado pelo autor.

Quanto ao critério de *MDA* o melhor resultado para cada período é observado em diferentes cenários, para o período de 2008 a 2022, 2016 à 2022 e 04/2020 à 2022 o melhor resultado está no cenário 3 com duas camadas ocultas, para o período de 2008 a 2016 o melhor resultado está no cenário 1 com duas camadas ocultas e para o período de 08/2020 à 2022 o melhor resultado está no cenário 1 com uma camada oculta.

6 CONCLUSÃO

Neste trabalho foi testada a eficiência da RNA do tipo *MLP* com treinamento via *backpropagation* na aplicação de previsão do valor de fechamento do dia seguinte para o ativo BOVA11. Um dos grandes desafios desse tipo de previsão, vem da natureza não normal da variação encontrada nos valores das ações, mesmo atingindo valores de *MAPE* abaixo de 1%, um aspecto mais interessante de análise foi visto no valor do *MDA* que atingiu valores um pouco acima de 50% em alguns casos, uma porcentagem um pouco maior de acerto seria ideal, porém com um acerto superior a 50% já é possível apresentar ganhos quando tomada opções de compra e venda de ações.

Um ponto notável se dá na divisão da série histórica da ação, quando colocada a série inteira como base de treinamento, vemos que os resultados acabam sendo bem ruins. Nesse trabalho foi constatado que dividir a série em diferentes intervalos, que apresentam comportamento semelhante é uma alternativa melhor, resultando em melhores índices de *MDA* e *MAPE*, isso fica evidente quando todas as divisões feitas na base, apresentaram um resultado melhor do que a base de dados completa, ressaltando também o período da pandemia de *COVID-19*, onde a remoção do período instável causado pela pandemia na bolsa de valores, melhorou o resultado da rede em alguns cenários. Nesse caso também foi observado que mesmo com a diminuição do tamanho da base de dados série que abrange o período de 08/2020 até 2022 em 84% quando comparada com a base de dados da série completa, a rede ainda conseguiu realizar previsões com resultados satisfatórios.

Um ponto que vale notar é a melhora dos resultados referentes ao *MAPE* quando adicionada a variável referente ao dia ser útil ou não. Com a adição da variável referente ao dia da semana da cotação, se teve uma melhora nos resultados do *MDA*, uma boa alternativa seria a utilização desses dois cenários de forma paralela, a fim de se ter uma visão mais completa da previsão, possibilitando uma escolha mais assertiva das opções de compra e venda de ações.

Em trabalhos futuros seria um bom tema de estudo, a comparação entre mais tipos de rede neural e mais tipos de treinamento, visando achar aquele que atinge melhores resultados na previsão de valores do mercado de ações.

REFERÊNCIAS

BANCO DO BRASIL (Brasil). **Mercado de Ações**. 2022. Disponível em: [https://www.bb.com.br/pbb/pagina-inicial/compra-e-venda-de-acoes/guia-do-investidor/mercado-de-acoes#/. Acesso em: 15 nov. 2022.](https://www.bb.com.br/pbb/pagina-inicial/compra-e-venda-de-acoes/guia-do-investidor/mercado-de-acoes#/)

BANCO DO CENTRAL DO BRASIL (Brasil). **Banco Central do Brasil**. 2022. Disponível em: [https://www.bcb.gov.br/. Acesso em: 15 nov. 2022.](https://www.bcb.gov.br/)

BLACKROCK (Brasil). **BOVA 11**. 2022. Disponível em: <https://www.blackrock.com/br/products/251816/ishares-ibovespa-fundo-de-ndice-fund>. Acesso em: 04 set. 2022.

CANILLAS, Salvador Falcón. **PREVISÃO DO ÍNDICE BURSÁTIL IBEX 35 USANDO REDES NEURAIS ARTIFICIAIS**. 2021. 72 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Engenharia Elétrica, Unesp - Câmpus de Ilha Solteira, Ilha Solteira, 2021. Disponível em: https://repositorio.unesp.br/bitstream/handle/11449/204724/falc%c3%b3n_canillas_s_me_ilha.pdf?sequence=3&isAllowed=y. Acesso em: 04 set. 2022.

CHOUDHURY, Sasmita S.; SEN, Moumita. **Trading in Indian Stock Market Using ANN: A Decision Review**. 2017. Disponível em: https://amsemodelling.com/publications/advances_in_modelling/General_Mathematics/542/54.2_09.pdf. Acesso em: 28 nov. 2022.

FORMAGGIO, Giovanni Panegossi. **Previsão de Demanda de Carregamento para Veículos Elétricos a Curto Prazo Utilizando Rede Neural Artificial**. 2021. 94 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Engenharia Elétrica, Unesp - Câmpus de Ilha Solteira, Ilha Solteira, 2021.

HAYKIN, Simon. **Neural Networks and Learning Machines**. 3. ed. Hamilton: Pearson Prentice Hall, 2009.

KAUPA, Paulo Henrique. **APLICAÇÃO DE TÉCNICAS DA INTELIGÊNCIA ARTIFICIAL NA SELEÇÃO DE AÇÕES PARA INVESTIMENTO NA BOLSA DE VALORES DE SÃO PAULO**. 2013. 156 f. Dissertação (Mestrado) - Curso de Engenharia de Produção, Engenharia de Produção, Uninove, São Paulo, 2013.

Disponível em:

http://bibliotecatede.uninove.br/bitstream/tede/200/1/B_Paulo%20Henrique%20Kaupa.pdf. Acesso em: 15 nov. 2022.

KROSE, Ben; SMAGT, Patrick van Der. **An Introduction to Neural Networks**. 8. ed. Amsterdam: The University Of Amsterdam, 1996. 135 p. Disponível em:

<http://14.99.188.242:8080/jspui/bitstream/123456789/1991/1/An%20Introduction%20to%20Neural%20Networks.pdf>. Acesso em: 28 nov. 2022.

KADIMA. **Kadima Asset Management**. 2022. Disponível em:

<https://www.kadimaasset.com.br/>. Acesso em: 2 set. 2022.

MOHANTY, Shaswat; VIJAY, Anirudh; GOPAKUMAR, Nandagopan. StockBot: Using LSTMs to Predict Stock Prices. **Journal Of Banking And Financial**

Technology. Palo Alto, p. 1-14. 2 ago. 2022.

PÉREZ, Laura Macián. **Estudio de los efectos de las variables macroeconómicas sobre la Bolsa**. 2017. Disponível em:

<https://m.riunet.upv.es/bitstream/handle/10251/80051/MACI%C3%81N%20-%20Estudio%20de%20los%20efectos%20de%20las%20principales%20variables%20macroecon%C3%B3micas%20sobre%20la%20Bolsa.pdf?sequence=1&isAllowed=y>. Acesso em: 03 dez. 2022.

TORRES, Sérgio. **PREVISÃO DO PREÇO DE AÇÕES BRASILEIRAS**

UTILIZANDO REDES NEURAIIS ARTIFICIAIS. 2021. 53 f. Dissertação (Mestrado) - Curso de Administração de Empresas, Universidades Presbiteriana Mackenzie, São Paulo, 2021.

YAHOO FINANCE (Brasil). **BOVA 11**. 2022. Disponível em:

<https://finance.yahoo.com/quote/BOVA11.SA/?guccounter=1>. Acesso em: 04 set. 2022.

WERBOS, Paul J. **Backpropagation Through Time: What It Does and How to Do It**. Cambridge: Us Government, 1978.