

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ECONOMIA

BRUNO CASSARÁ GOMES

**ANTECIPAÇÃO DOS MOVIMENTOS DE PREÇOS DE AÇÕES ATRAVÉS DE
REDES NEURAS ARTIFICIAIS**

JUIZ DE FORA – MG
2023

BRUNO CASSARÁ GOMES

**ANTECIPAÇÃO DOS MOVIMENTOS DE PREÇOS DE AÇÕES ATRAVÉS DE
REDES NEURAIS ARTIFICIAIS**

Trabalho de Conclusão de Curso
submetido ao curso de Ciências
Econômicas da Universidade Federal
de Juiz de Fora, como requisito parcial
para obtenção de título Bacharel em
Ciências Econômicas.

JUIZ DE FORA – MG
2023

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Gomes, Bruno Cassará.

Antecipação dos Movimentos de Preços de Ações através de Redes Neurais Artificiais / Bruno Cassará Gomes. -- 2023.
29 p.

Orientador: Rogério Silva De Mattos

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Juiz de Fora, Faculdade de Economia, 2023.

1. Ensemble. 2. Redes Neurais Artificiais. 3. Séries Temporais Financeiras. I. De Mattos, Rogério Silva, orient. II. Título.



UNIVERSIDADE FEDERAL DE JUIZ DE FORA
REITORIA - FACECON - Depto. de Economia

Na data de 13/7/2023, a Banca Examinadora, composta pelos professores

1 – Rogério Silva de Mattos - orientador; e

2 – Paulo César Coimbra Lisboa,

reuniu-se para avaliar a monografia do acadêmico Bruno Cassará Gomes, intitulada: “Antecipação dos Movimentos de Preços de Ações Através de Redes Neurais Artificiais”.

Após primeira avaliação, resolveu a Banca sugerir alterações ao texto apresentado, conforme relatório sintetizado pelo orientador. A Banca, delegando ao orientador a observância das alterações propostas, resolveu APROVAR a referida monografia



Documento assinado eletronicamente por **Rogério Silva de Mattos, Professor(a)**, em 18/07/2023, às 08:53, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Paulo César Coimbra Lisboa, Professor(a)**, em 18/07/2023, às 11:45, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf (www2.ufjf.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **1370361** e o código CRC **2A788DFD**.

RESUMO

A pesquisa tem como contexto o aumento de pessoas investindo suas poupanças como forma de atingir algum objetivo, seja o lucro ou a defesa contra alguma perda de patrimônio. Por consequência, as Redes Neurais Artificiais (NRAs) são empregadas cada vez mais nos mercados financeiros e estudadas em âmbito acadêmico como uma ferramenta para previsão de preço de ativos. Dadas as inúmeras possibilidades que a arquitetura de RNAs pode ter e a grande quantidade de ativos que podem ser previstos, a pesquisa possui como objetivo verificar a capacidade de RNAs em prever o movimento do preço da ação VALE3, bem como avaliar sua acuracidade. Para esse fim, foram construídas duas RNAs do tipo Perceptron e um módulo agregador, os quais formam um ensemble. Após 20 experimentos sensibilizando a arquitetura das RNAs, o ensemble vencedor apresenta taxa de acurácia global de 57,89%, superior a ambas RNAs individualmente, além de apresentar maior acuracidade em momentos de descida, o que favorece posições de hedge.

Palavras-chave: Ensemble, Redes Neurais Artificiais, Séries Temporais Financeiras.

ABSTRACT

The context of the research is the increase in the number of people investing their savings to gain some profit or hedge their portfolio. Consequently, Artificial Neural Networks (ANNs) are used in financial markets and studied to predict the asset's price. As there are a lot of possibilities for the architecture of ANNs and a high number of assets, the research aims to verify the capacity of ANNs to predict the movement of the price of the stock VALE3 and measure their accuracy. To achieve this aim, two ANNs and one aggregator module are constructed, which form the ensemble. After 20 experiments changing the architecture of ANNs, the best ensemble has a global accuracy equal to 57,89%, higher than both ANNs. It is more accurate to predict down movements than up movements, and the situation is better to hedge.

Keywords: Ensemble, Artificial Neural Networks, Financial Time Series.

LISTA DE GRÁFICOS

Gráfico 1 - Preço da Ação da VALE3.....	20
Gráfico 2 - Volume Negociado da Ação VALE3.....	21
Gráfico 3 - Observações Reais.....	21
Gráfico 4 - Frequências de Saídas Reais (Down e Up) da Base de Dados	22
Gráfico 5 - Acurácia das RNAs e do Ensemble	25

LISTA DE FIGURAS

Figura 1 - Estrutura genérica de RNA	14
Figura 2 - RNA com um neurônio	15
Figura 3 - RNA artificial perceptron	18

LISTA DE TABELAS

Tabela 1 - Ilustração da Matriz de Confusão	18
Tabela 2 - Arquitetura das RNAs.....	23
Tabela 3 - Experimentos com as RNAs para a seleção do melhor ensemble.....	24
Tabela 4 - Métricas de performance do experimento 12	25

SUMÁRIO

1 INTRODUÇÃO	10
2 REVISÃO DE LITERATURA.....	11
3 METODOLOGIA	14
3.1 RNAs.....	14
3.2 Aprendizado	15
3.3 Ensembles	16
3.4 O modelo.....	17
3.5 Métricas de performance	18
3.6 Implementação computacional.....	19
4 BASE DE DADOS.....	20
4.1 Yahoo! Finance	20
5 RESULTADOS.....	20
5.1 Variáveis.....	20
5.2 Construção do ensemble.....	22
6 CONCLUSÃO.....	26
REFERÊNCIAS.....	27

1 INTRODUÇÃO

A finalidade de muitas aplicações financeiras é a obtenção do lucro, o qual pode ser mensurado financeiramente pelo retorno obtido através da aplicação do capital. Para atingir esse objetivo, espera-se que os agentes econômicos busquem por uma otimização dos meios para alcançar tal finalidade. Com o avanço da tecnologia, isso significa se valer da inteligência artificial para previsões de séries temporais financeiras, como valores futuros de ações, índices, cotas de fundos de investimento, entre outros ativos. Além do propósito de lucrar, existe o intuito de se proteger de perdas, as posições de hedge; objetivo que também pode ser otimizado por meio de inteligência artificial.

Conforme Glantz e Kissell (2013), 85% das operações de compra e venda de ações foram realizadas por meio de algoritmos de previsão em 2012, nos Estados Unidos (EUA), criando um campo de *algotrading* (ou seja, *algorithmic trading*). Nessa área, existem duas divisões que se diferenciam ligeiramente: aquelas que se realizam a partir da sistematização de entradas e saídas com base em indicadores técnicos (suportes e resistências); e outras que se valem de algoritmos de previsão, caso que será abordado nesta pesquisa.

Primeiramente nos EUA e, posteriormente, nos países subdesenvolvidos, esse movimento atinge o meio acadêmico, sendo hoje objeto de estudo não só das ciências computacionais como também das ciências econômicas. Além disso, o número de investidores cresce a cada ano (LARGHI, 2022), especialmente no Brasil, popularizando as discussões sobre mercado financeiro e, conseqüentemente, sobre o uso da inteligência artificial em finanças.

Diante desse contexto, a inteligência artificial tem sido empregada cada vez mais entre os estudiosos, numa ampla gama de aplicações. Em Nelson *et al.* (2017), a direção do preço de ações da Bolsa de Valores de São Paulo (BOVESPA) foi prevista por meio de Redes Neurais Artificiais (RNAs), em específico as *Long-Short Term Memory* (LSTM), usadas para construir um modelo de classificação. As RNAs estão entre as técnicas mais utilizadas para prever valores futuros ou tendências dos mercados de ações ao redor do mundo (ATSALAKIS; VALAVANIS, 2009). Em Kara *et al.* (2011), busca-se discutir a acuracidade de RNAs na previsão de ações em contextos de alta volatilidade. Enquanto em O'Connor e Madden (2006), tenta-se prever o valor de fechamento do Índice Dow Jones (DJIA) por meio de RNAs *feedforward* treinadas com

backpropagation. Esse índice reflete o desempenho das ações de trinta empresas de grande porte dos EUA. Caso se preveja uma alta, o método compra uma ação hipotética representativa do índice, possuindo seu rendimento. No dia seguinte, repete-se o processo: se o método prevê uma nova alta, a posição de compra é mantida, senão, a ação é vendida imediatamente a partir da abertura do mercado. Por sua vez, este trabalho tem como uma das principais referências Giacomel (2016), dissertação de mestrado que propõe o uso de ensembles formados por RNAs para classificar as saídas de modelos matemáticos, valendo-se dos resultados para comprar ou vender ações.

Os aprimoramentos das RNAs, a exemplo do que é exposto em Giacomel (2016), estão contribuindo para um avanço das discussões sobre o tema no âmbito acadêmico. No entanto, cabe ressaltar a existência de um espaço para ampliação da fronteira desse conhecimento, especialmente no Brasil. É um vasto campo de estudo, já que existem diversos ativos financeiros (cotas de fundos de investimento, ações brasileiras, ações americanas, índices de *small caps*, índices tradicionais, derivativos de commodities), bem como várias propostas de arquiteturas para RNAs (com ou sem ensembles, uma camada ou múltiplas camadas, treinada com *backpropagation* ou não etc.).

Como há ainda espaços para ampliar a aplicação de RNAs no contexto financeiro, o presente trabalho tem como objetivo geral verificar se há capacidade das RNAs em prever os movimentos de alta e baixa dos preços das ações e analisar o grau de acuracidade dessas previsões, baseando-se nas referências aqui apresentadas. A partir dos resultados, espera-se apresentar uma análise que acrescente à discussão sobre RNAs direcionadas às finanças.

Assim, esta monografia está organizada em seis capítulos, são eles: “Introdução”; “Revisão de literatura”, que expõe os estudos que fundamentaram a proposta desse trabalho; “Metodologia”, que está dividida em seis seções (RNAs, Aprendizado, Ensemble, Modelo, as Métricas de Performance e Implementação Computacional); “A Base de Dados”, trazendo a seção Yahoo! Finance; em seguida, os “Resultados”; e, por fim, a “Conclusão”.

2 REVISÃO DE LITERATURA

O trabalho de Rocha (2011) defende o uso de RNAs para a previsão do preço

de ações, devido à capacidade em superar dificuldades encontradas pelos métodos tradicionais, conseguindo lidar com dados ruidosos e reconhecer padrões. Com isso, foram formadas 10 RNAs na previsão do preço de quatro ações da BOVESPA, a saber: AMBV3 (Ambev – ordinária), PETR4 (Petrobras – preferencial), VALE3 (Vale – ordinária) e BBDC4 (Bradesco – preferencial). Essas RNAs se diferenciam pelo número de camadas de neurônios, quantidade de neurônios e pela função de ativação. Como conclusão, os resultados foram satisfatórios em termos de capacidade de previsão, porém, ressalta-se que é importante definir uma arquitetura específica para cada tipo de ação.

Em Kara *et al.* (2011), utilizaram-se RNAs para previsões de índices de preços de ações em contextos de alta volatilidade. Os autores apontam a dificuldade em previsões desse tipo, já que o movimento acionário depende de várias variáveis, por exemplo, mudanças macroeconômicas, expectativas dos investidores, psicologia dos investidores e movimento de outros mercados. Esse estudo analisou o principal índice acionário da Bolsa de Istanbul, Turquia, o *Istanbul Stock Exchange* (ISE). O objetivo principal foi prever a direção do movimento diário do índice através de RNAs. Como conclusão, o modelo de RNA demonstrou significativa performance em prever a direção do preço das ações. Além disso, outra contribuição relevante de Kara *et al.* (2011) é a aceitação de uma queda da capacidade de previsão dos modelos em momentos de crises econômicas.

Em Nelson *et al.* (2017), são construídas RNAs LSTM. Esse tipo de RNA se diferencia das RNAs *feedforward* por haver conexão em múltiplas direções. Isto é, os neurônios podem enviar dados para neurônios de camadas anteriores ou da mesma camada. O objetivo também era prever o movimento do preço das ações. Os ativos analisados foram: a ação preferencial do Bradesco (BBDC4), a ação preferencial do Itaú Unibanco (ITUB4), a ação ordinária da Cielo (CIEL3), a ação ordinária da Petrobras (PETR4) e o fundo de índice BOVA11. Como conclusão, esse estudo defende que o algoritmo revelou uma capacidade aceitável de aprendizagem, superando outros modelos analisados. No entanto, ressalta-se que a variância de cada modelo poderia ser menor.

Muitas séries temporais são previstas apenas por meio de dados passados, no entanto, esse tipo de relação não captura a importância de outras variáveis nos movimentos da série. O'Connor e Madden (2016) defendem que os preços das ações são afetados por fatores internos e externos, envolvendo desde variáveis, como

produto interno bruto (PIB), até a taxa básica de juros de mercados estrangeiros. Segundo o estudo, os fatores externos tenderiam a afetar as companhias de uma mesma maneira: se um bem natural, como energia, aumenta de preço, isso implica em uma elevação de custos para as empresas. Conforme o estudo, fica claro para os autores que a adição de fatores externos, como variáveis explicativas do modelo, melhora a capacidade preditora da RNA. O trabalho envolveu seis experimentos que buscavam prever o valor de fechamento do principal índice americano (DJIA). Dois experimentos que merecem destaque são, primeiro, os modelos em que existiram a adição do preço do petróleo e, segundo, a adição da taxa de câmbio corrente como variáveis explicativas do modelo, as quais, ao serem adicionadas, melhoraram a capacidade preditora da RNA.

Em relação à principal referência deste projeto, Giacomel (2016) enfatiza a dificuldade em prever o valor que uma ação terá em um período futuro, o que faria com que o movimento das ações fosse mais vantajoso de se prever, abordagem empregada em estudos citados. O trabalho propõe a previsão de séries temporais financeiras por meio de dois ensembles formados por duas RNAs do tipo *perceptron*, combinando os resultados das RNAs: se as duas RNAs obtiverem o mesmo resultado (subida e subida, ou, descida e descida), o ensemble tem como saída o resultado unânime das RNAs; do contrário, o resultado é “não sabe”. Portanto, são três possíveis saídas: a ação irá subir, descer ou “não [se] sabe”.

A base de dados usada por ele é composta por dois grupos: ações norte-americanas e ações brasileiras. Entre as do Brasil, estão o índice de ações da BOVESPA (BOVA11); ações ordinárias do Banco do Brasil (BBAS3), BB Seguridade (BBSE3), BRF *Foods* (BRFS3) e BMF BOVESPA (BVMF3); e ações preferenciais do Bradesco (BBDC4), do Itaú (ITSA4), da Petrobras (PETR4) e da Vale (VALE5). Os resultados foram comparados a duas estratégias, a *Buy and Hold* e a *Trivial*. A primeira se caracteriza por uma operação de compra feita no início de um período e vendida novamente só após um período muito longo, que pode se estender até mesmo por vários anos. Já a segunda estratégia considera que, se uma ação subiu (ou caiu) durante o período t , a ação também irá subir (ou cair) no período $t+1$. Pela ótica do autor, tanto em relação às ações brasileiras quanto às estadunidenses, os resultados foram “bastante satisfatórios”, sendo melhores em comparação às outras abordagens.


3 METODOLOGIA

Este trabalho desenvolveu duas RNAs do tipo *perceptron* multicamadas e um módulo agregador que formam um ensemble. Ensemble é um método que combina as saídas das RNAs de forma a aprimorar a acuracidade da previsão final. As duas RNAs possuem os mesmos *inputs*, porém se diferenciam pela arquitetura. As possibilidades de *output* são as mesmas: a variável direção do preço da ação (sobe ou desce). Por fim, as métricas de avaliação da performance das RNAs e do ensemble aqui adotadas foram o Erro Quadrático Médio (EQM) e as taxas de acerto e precisão obtidas das matrizes de confusão.

3.1 RNAs

RNAs são técnicas computacionais que incorporam um modelo matemático e desenvolvem uma inteligência através da experiência, processo similar a certas estruturas neurais de organismos vivos, como o cérebro humano (CARVALHO, 2009). Elas são formadas por camadas, que podem ser de entrada, oculta e de saída. A figura 1 representa uma estrutura genérica de uma RNA.

Figura 1 - Estrutura genérica de RNA




Fonte: Autor.

Nessa figura, a RNA apresentada possui quatro unidades de entrada na camada de entrada (*input*), cinco neurônios na camada oculta (*hidden*) e um neurônio na camada de saída. Isso configura um primeiro aspecto importante da RNA, ou seja,

sua arquitetura. Os neurônios estão em todas as camadas, exceto a de entrada, composta pelas unidades de entrada. Os neurônios interagem entre si num processo chamado de *sinapse*: sinais são apresentados às unidades de entrada que, por sua vez, são repassados aos neurônios. Em cada neurônio, cada sinal é multiplicado por um peso, ponderando sua participação. Em seguida, é feito o somatório dos sinais ponderados, e o resultado é aplicado a uma função de ativação, que define a saída da RNA.

Por exemplo, na figura 2, a entrada consiste de um vetor de observações das variáveis preditoras providas pelo usuário. O vetor de observações contém x_1 , x_2 e x_3 , enquanto w_0 , w_1 , w_2 e w_3 correspondem ao vetor de pesos da RNA. O núcleo representa a função de ativação, enquanto a saída da RNA é representada por Y , embutindo um padrão de ligação com a entrada. Bias é um parâmetro adicional que é usado para ajustar a saída junto da soma ponderada das entradas para o neurônio.

Figura 2 - RNA com um neurônio



Fonte: Autor.

3.2 Aprendizado

A cada nova iteração, os pesos têm seus valores atualizados, constituindo o segundo componente das RNAs, isto é, o algoritmo de aprendizado. É através desse mecanismo de atualização dos pesos que a RNA aprende, a fim de tornar saídas projetadas mais próximas possíveis de saídas reais. O aprendizado se dá através de

uma regra, que explicaremos a seguir.

A cada iteração, a RNA comete um erro conforme a equação:

$$e(n) = d(n) - y(n) \quad (1)$$

Em que $e(n)$ é o erro para o n -ésimo dado do conjunto de treinamento; $d(n)$ é a saída correta à n -ésima entrada; e $y(n)$ é a saída produzida pelo neurônio para n -ésima entrada. Com a definição do erro, calcula-se:

$$\Delta_i(n) = \lambda * e_i(n) * x(n) \quad (2)$$

Em que $\Delta_i(n)$ representa a variação do i -ésimo peso de conexão (sinapse) da RNA; λ é a taxa de aprendizado, constante e pré-determinada; e $x(n)$ é o vetor de entrada da RNA.

Tem-se ainda, a equação 3, em que são calculados os novos pesos a cada nova iteração da RNA.

$$w_i(n + 1) = w_i(n) + \Delta_i(n) \quad (3)$$

Em que $w_i(n+1)$ é o i -ésimo peso da RNA para o momento $n+1$; e $w_i(n)$ é o i -ésimo peso da RNA para o momento n .

3.3 Ensembles

Ensemble é um método que combina as saídas de duas ou mais RNAs. Em um ensemble básico, a combinação se dá por meio da média das saídas das RNAs, como na fórmula 4:

$$f = \frac{1}{n} \sum_{j=1}^n f_j(x) \quad (4)$$

Em que x é o vetor de entrada da RNA; $f_j(x)$ é a saída da RNA para j -ésima observação; e n é a quantidade de observações.

Além das duas RNAs, existe um terceiro elemento na formação do ensemble: o módulo agregador, responsável por combinar as saídas das RNAs. À medida que

as RNAs são treinadas, a combinação das saídas das RNAs produz a saída final (*output*) do ensemble. Cada RNA tem a mesma variável de saída, que retorna “*down*”, caso a previsão seja de queda do preço, ou “*up*”, caso a previsão seja de subida do preço. O módulo agregador combina ambas as saídas das RNAs da seguinte forma:

- Se ambas previrem “*up*”, a saída do módulo agregador é “*up*”;
- Se ambas previrem “*down*”, a saída do módulo agregador é “*down*”;
- Caso haja divergência, a saída do módulo agregador é “não sabe”.

No contexto de inteligência artificial aplicada a finanças, usar ensembles tem como objetivo aproveitar as saídas das RNAs para prever com maior precisão os valores futuros de séries temporais.

3.4 O modelo

É desenvolvido um modelo não linear através de RNAs, relacionando a variável de saída d_i com um conjunto de variáveis de entrada x_1, x_2, \dots, x_k . No caso, a variável de saída aqui considerada é o movimento de subida ou descida. A equação 5 é uma forma genérica de um modelo não linear:

$$d_i = f(x_i) + \varepsilon_i \quad (5)$$

Em que d_i é o i -ésimo dado para a variável de saída; x_i é o i -ésimo dado para o conjunto de variáveis preditoras; enquanto ε_i é o erro para a i -ésima observação.


Existem duas RNAs. Uma é formada por sete variáveis independentes, a saber: ano; os preços em um, dois, três, quatro e cinco dias anteriores ao dia em questão; e do volume transacionado. A segunda RNA possui exatamente as mesmas variáveis preditoras, porém, sua arquitetura é diferente – a qual será detalhada na seção de resultados. Em ambos os modelos, a variável de saída é tratada como uma variável qualitativa, *up* (subida) ou *down* (descida), o que significa que não é prevista a magnitude de variação do preço de uma ação, mas apenas a direção da variação (positiva ou negativa). Essa informação é útil para os agentes econômicos, uma vez que possibilita definir se a ação deverá ser mantida ou vendida.

É empregado o uso de ensembles, isto é, valer-se das combinações das saídas

das duas RNAs. Se as duas RNAs tiverem o mesmo resultado (subida e subida, ou descida e descida), o ensemble tem como saída o resultado unânime das RNAs. Do contrário, o resultado é “não sabe”. Portanto, são três possíveis saídas para o ensemble: a ação irá subir, descer ou “não sabe”.

As RNAs são do tipo *perceptron* multicamadas, um modelo matemático que recebe várias entradas (x_1, x_2, \dots, x_n) e produz uma única saída binária, logo, é um classificador binário para problemas linearmente separáveis. A figura 3 representa uma RNA com uma camada de entrada e três camadas de neurônios, sendo duas ocultas:

Figura 3 - RNA artificial perceptron



Fonte: Autor.

3.5 Métricas de performance

Foram utilizadas duas métricas de performance: as taxas de acerto, que foram calculadas com base na matriz de confusão, e o Erro Quadrático Médio (EQM). A matriz de confusão corresponde a uma tabela em que é apresentada a ocorrência real de cada possível saída e a ocorrência de cada possível previsão, permitindo estabelecer o aproveitamento da RNA.

Tabela 1 - Ilustração da Matriz de Confusão

		Previsões	
		A	B
Alvos	A	40	45
	B	60	55

Fonte: Autor.

Para cada matriz, são calculadas cinco taxas de performance:

- Taxas de Acertos A: na ilustração, é igual a 47,06% ($40/(40+45)$).
- Taxas de Acertos B: na ilustração, é igual a 47,83% ($55/(60+55)$).
- Taxas de Precisão A: na ilustração, é igual a 40,00% ($40/(40+60)$).
- Taxas de Precisão B: na ilustração, é igual a 55,00% ($55/(45+55)$).
- Taxa de Acerto Global (Acurácia): na ilustração, é igual a 47,5% ($(40+55)/200$).

Independente do caso, a taxa de acerto global é sempre igual à taxa de precisão global.

3.6 Implementação computacional

A linguagem de programação utilizada para o desenvolvimento do trabalho é a linguagem R, e a interface de edição é o R Studio, integrado ao primeiro. Conforme o site oficial¹, “R é um ambiente de software livre para computação estatística e gráficos. Ele compila e roda em uma ampla variedade de plataformas UNIX, Windows e MacO.” (R Development Core Team, 2009). A linguagem foi criada originalmente por acadêmicos do Departamento de Estatística da Universidade de Auckland, Nova Zelândia.

São utilizados três pacotes (bibliotecas de códigos): o RSNNS, o NeuralNetTools e o readxl. O primeiro corresponde a uma biblioteca de código que envolve o funcionamento de RNAs e foi criado por Christoph Bergmeir (2012). A segunda biblioteca foi criada por Marcus W. Beck (2018) e auxilia na visualização e interpretação de modelos de RNAs. Por fim, a terceira biblioteca serve para importar arquivos Excel para R e tem como autores Hadley Wickham e Jennifer Bryan.

Consultou-se os seguintes materiais digitais para o uso das bibliotecas: primeiro, Bergmeir (2023)², um manual de referência para a biblioteca RSNNS; segundo, Wickham *et al.* (2023)³, manual para a biblioteca readxl; por fim, Beck (2022), referência para a biblioteca NeuralNetTools⁴.

¹ <https://www.r-project.org/>

² <https://cran.r-project.org/web/packages/RSNNS/RSNNS.pdf>

³ <https://cran.r-project.org/web/packages/readxl/readxl.pdf>

⁴ <https://cran.r-project.org/web/packages/NeuralNetTools/NeuralNetTools.pdf>

4 BASE DE DADOS

4.1 Yahoo! Finance

O Yahoo! Finance é um segmento do grupo Yahoo! focado em fornecer notícias financeiras, dados e comentários; não produzindo dados, apenas disponibilizando-os. Entre os dados que podem ser acessados encontram-se cotações de ações brasileiras, ações americanas, índices brasileiros, índices americanos, contratos futuros, moedas e commodities. O período da série histórica e a periodicidade (diária, semanal ou mensal) variam de acordo com o ativo em questão.


Através do Yahoo! Finance foram coletadas as cotações das ações da VALE3 e o volume negociado, ambos com frequência diária.

5 RESULTADOS

5.1 Variáveis


Após a definição das variáveis explicativas e a determinação da variável de saída, como a subida ou descida do preço da ação ordinária da Vale (VALE3), foram gerados os gráficos das seguintes variáveis: preço das ações ordinárias VALE3 em um instante de tempo t e o volume de negociações das ações VALE3. Os gráficos 1 e 2 mostram as séries históricas que se iniciam em janeiro de 2007 e se encerram em dezembro de 2013. O ativo foi escolhido por ser uma das ações mais líquidas da bolsa, e o intervalo de tempo foi selecionado de forma aleatória pelo autor.

Gráfico 1 - Preço da Ação da VALE3



Fonte: Autor.

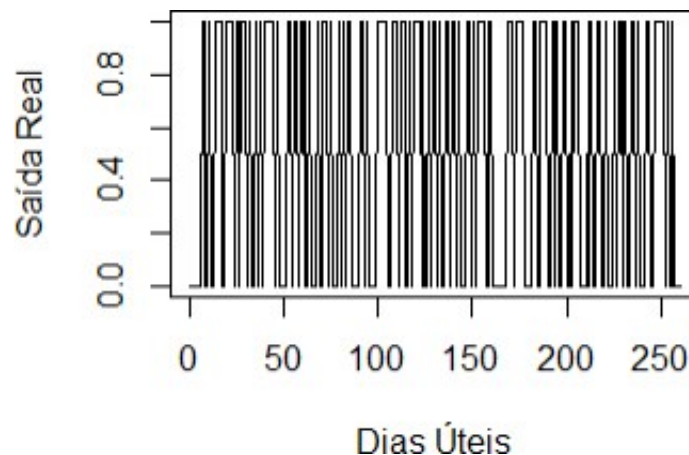
Gráfico 2 - Volume Negociado da Ação VALE3



Fonte: Autor.

O modelo possui uma única variável de saída, que é a direção do preço da ação. Como há somente duas possibilidades, descida ou subida, a variável de saída é do tipo binária. Ambas RNAs são treinadas no conjunto de treinamento, que possui as 1471 primeiras observações, e a avaliação da performance das RNAs ocorre no conjunto de teste, que possui 260 observações. O gráfico 3 mostra as observações reais fornecidas pela base de dados, ou seja, a direção que o preço da ação teve de fato.

Gráfico 3 - Observações Reais



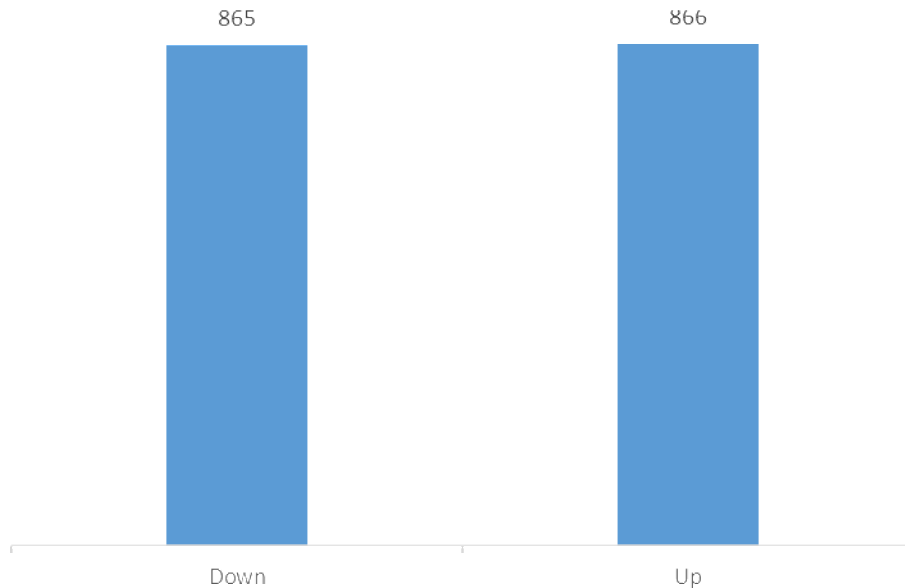
Fonte: Autor.

O formato do gráfico se deve ao fato da existência exclusiva de duas possibilidades, subida e descida, que no caso do gráfico 3 são correspondentes ao

valor de 1 e 0 respectivamente.

O gráfico 4 mostra a quantidade de *down* e *up* que há nas observações reais:

Gráfico 4 - Frequências de Saídas Reais (*Down* e *Up*) da Base de Dados



Fonte: Autor.

Ao longo do período de dados coletados, observa-se que houve 865 dias em que houve queda do preço da ação; enquanto existiram 866 dias em que houve aumento do preço da ação.

5.2 Construção do ensemble

A construção de arquitetura de RNAs é um processo infinito, já que há inúmeros valores possíveis para os pesos sinápticos que determinam a capacidade preditora da RNA. Isso decorre da flexibilidade de se configurar uma RNA com diferentes números de neurônios e de camadas, o que leva a um maior ou menor número de pesos sinápticos a serem atualizados no treinamento. Outros parâmetros também precisam ser definidos no treinamento de uma RNA, como a distribuição dos dados entre treinamento e teste, o número máximo de iterações, a taxa de aprendizado e a semente do gerador de números aleatórios usado para inicializar a atualização dos pesos sinápticos. No entanto, essa flexibilidade traz problemas para definir a melhor arquitetura possível, e uma das soluções é experimentar várias configurações e, assim, fazer vários experimentos, a fim de se determinar e comparar as taxas de

acurácia e performance finais. A tabela 2 sintetiza as configurações usadas na busca da melhor arquitetura para as duas RNAs do ensemble.

Tabela 2 - Arquitetura das RNAs

Configurações	RNA1	RNA2
Percentual de observação no conjunto de teste	15%	15%
Tamanho do conjunto de treinamento	1471	1471
Tamanho do conjunto de teste	260	260
Número de neurônios	V.E.	V.E.
Número máximo de iterações	5000	5000
Semente do gerador de n.a.	9	9
Taxa de aprendizado	5%	5%

Fonte: Autor. Nota: V.E. = varia com o experimento; n.a. = números aleatórios.

Foram feitos 20 experimentos, em que cada experimento consiste em testar uma arquitetura diferente para as RNAs. Para facilitar a sensibilização, variou-se somente o número de neurônios da camada intermediária de ambas as RNAs, limitando-se o universo de cenários. Além disso, arquiteturas idênticas em ambas as RNAs implicam exatamente nas mesmas saídas, o que não é vantajoso para o objetivo final, dado que o ensemble é construído justamente para diminuir a incerteza entre duas redes diferentes. O experimento mais efetivo foi aquele em que a acurácia global do ensemble é maior. É importante destacar que, para o cálculo da acurácia global do ensemble, as previsões “não sabe” são excluídas, logo, a performance é computada somente em resultados unânimes entre as redes. A tabela 3 apresenta os experimentos, resumindo os resultados em termos da arquitetura usada para cada RNA (número de neurônios na camada intermediária) e do EQM do ensemble obtido em cada experimento.

Tabela 3 - Experimentos com as RNAs para a seleção do melhor ensemble

Experimento	Rna1	Rna2	Eqm do ensemble
	Arqt.	Arqt.	
1	1	20	0,528
2	20	1	0,528
3	10	10	0,565
4	12	11	0,550
5	8	9	0,568
6	7	9	0,556
7	7	8	0,571
8	7	18	0,558
9	7	30	0,551
10	20	30	0,525
11	9	8	0,568
12	18	19	0,579
13	19	20	0,574
14	14	15	0,538
15	13	14	0,557
16	10	15	0,558
17	22	20	0,504
18	18	17	0,542
19	15	16	0,543
20	12	11	0,550

Fonte: Autor. Nota: Arqt. = Arquitetura (número de neurônios).

Entre os experimentos, houve casos em que somente um único neurônio estava presente na camada: o objetivo foi ver a capacidade preditora da rede em cenários extremos. Por outro lado, existiram experimentos em que a quantidade de neurônios era muito próxima, a exemplo dos experimentos 4 e 5 (tabela 3), permitindo verificar a qualidade das RNAs nesses contextos.

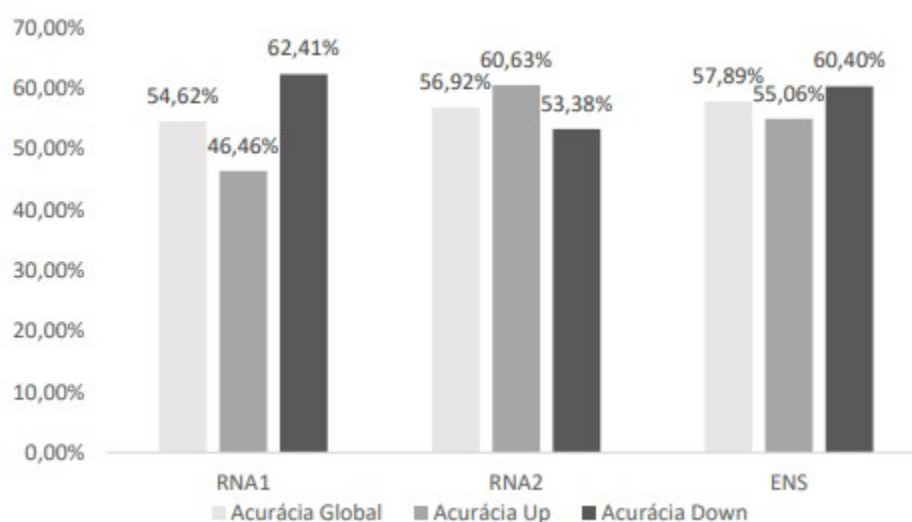
O ensemble do experimento 12 apresentou uma acurácia global de cerca de 57,89%, obtendo o melhor resultado. Nesse são 18 e 19 neurônios nas camadas intermediárias nas RNA 1 e RNA 2, respectivamente. A tabela 4 apresenta todas as taxas de acurácia e precisão obtidas no experimento 12, o vencedor, bem como a percentagem de saídas “não sabe” do ensemble; enquanto o gráfico 5 ilustra graficamente os mesmos resultados.

Tabela 4 - Métricas de performance do experimento 12

	RNA1	RNA2	ENS	PNSE %
Acurácia Global	54,62%	56,92%	57,89%	26,2
Acurácia <i>Up</i>	46,46%	60,63%	55,06%	
Acurácia <i>Down</i>	62,41%	53,38%	60,40%	
Precisão <i>Up</i>	54,13%	55,40%	55,06%	
Precisão <i>Down</i>	54,97%	58,68%	60,40%	

Fonte: Autor. Nota: ENS. = ensemble; PNSE. = porcentagem de "não sabe".

Gráfico 5 - Acurácia das RNAs e do Ensemble



Fonte: Autor.

Conforme a tabela 4, a acurácia global (57,89%) é um valor entre a acurácia para as previsões *up* (55,06%) e para as previsões *down* (60,40%). Esse resultado já era esperado, dado que um ensemble, considerando o método em questão, não tende a performar globalmente mais que previsões de *up* e previsões de *down*, simultaneamente. Em outros experimentos, as previsões de *up* e *down* foram mais distantes, no sentido do ensemble performar muito bem em *down*, mas muito mal em *up*, o que aponta um certo equilíbrio do experimento vencedor. Além disso, assim como todos os outros experimentos, a acurácia em *down* foi superior à acurácia em *up*. Logo, nas observações reais, ainda que a quantidade de *down* seja igual a de *up*, as RNAs construídas nesse trabalho têm maior capacidade preditiva em momentos de descidas, o que favorece posições mais defensivas (*hedge*) do que agressivas.

6 CONCLUSÃO

Esta pesquisa teve por objetivo criar uma ferramenta que pudesse auxiliar investidores na busca por lucro em operações de compra e venda de ações. Aprimorando um dos métodos já estabelecidos no mercado financeiro, as RNAs, foi utilizado o ensemble como forma de melhorar a performance das RNAs treinadas para a previsão do preço de ação da Vale (VALE3). Após 20 experimentos em que foram sensibilizadas diferentes arquiteturas de RNAs, um experimento ganhador provou a performance global melhor do ensemble em relação a outras duas RNAs componentes do módulo agregador.

Em relação às previsões de *down* e *up*, o ensemble performou melhor em previsões de *down*. O que sugere ser uma ferramenta melhor para investidores mais defensivos. Para casos em que o investidor tenha um perfil mais agressivo, seria necessário outra arquitetura de rede, ou, até mesmo, a adição de diferentes variáveis explicativas. O que dificultaria a objetividade na escolha da construção da RNA, mas, ao mesmo tempo, amplia as opções possíveis de determinação da função de regressão, da arquitetura da RNA, da amostra, entre outras.

Diante disso, para trabalhos posteriores, sugere-se a adição de variáveis macroeconômicas como variáveis explicativas do modelo, aproximando-o mais da realidade. O uso de ensemble deve ser mantido, podendo ser testado em situações em que há maior incerteza, por exemplo, momentos de turbulência econômica e política.

REFERÊNCIAS

ATSALAKIS, G. S.; VALAVANIS, K. P. Surveying stock market forecasting techniques—part ii: Soft computing methods. **Expert Systems with Applications**, Elsevier, v.36, n. 3, p. 5932–5941, 2009. Disponível em: <http://dx.doi.org/10.1016/j.eswa.2008.07.006>. Acesso em: 26 mar. 2023.

BECK, M. W. NeuralNetTools: Visualization and Analysis Tools for Neural Networks. **Journal of Statistical Software**, v. 85, n. 11, p. 1-20, 2018. Disponível em: <http://dx.doi.org/10.18637/jss.v085.i11>. Acesso em: 26 mar. 2023.

BECK, M. W. **Visualization and Analysis Tools for Neural Networks**. 2022. Disponível em: <https://cran.r-project.org/web/packages/NeuralNetTools/NeuralNetTools.pdf>. Acesso em: 26 mar. 2023.

BERGMEIR, C. **Neural Networks using the Stuttgart Neural Network Simulator**. 2023. Disponível em: <https://cran.r-project.org/web/packages/readxl/readxl.pdf>. Acesso em: 26 mar. 2023.

BERGMEIR, C.; BENÍTEZ, J. M. Neural Networks in R Using the Stuttgart Neural Network Simulator: RSNNS. **Journal of Statistical Software**, [S. l.], v. 46, n. 7, p. 1–26, 2012. Disponível em: <https://doi.org/10.18637/jss.v046.i07>. Acesso em: 29 apr. 2023.

CARVALHO, A. C. P. F. de. **Redes Neurais Artificiais**. RNAs. Disponível em: <https://encurtador.com.br/opBFH>. Acesso em: 28 jun. 2022.

GIACOMEL, F. dos S. **Um método algorítmico para operações na bolsa de valores baseado em ensembles de redes neurais para modelar e prever os movimentos dos mercados de ações**. 2016. Dissertação (Mestrado em Ciência da Computação) –Programa de Pós-Graduação em Computação, Instituto de Informática, Universidade Federal do Rio Grande do Sul, Porto Alegre: 2016. Disponível em: <http://hdl.handle.net/10183/134586>. Acesso em: 26 mar. 2023.

KARA, Y.; BOYACIOGLU, M. A.; BAYKAN, Ö. K. Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the istanbul stock exchange. **Expert systems with Applications**, Elsevier, v. 38, n. 5, p. 5311–5319, 2011. Disponível em: <https://doi.org/10.1016/j.eswa.2010.10.027>. Acesso em: 26 mar. 2023.

LAZZARIN, L. do N. A. **Método ensemble baseado em RNAs para estimação de interações por doenças respiratórias**. 2019. Dissertação (Mestrado em Ciência da Computação) – Programa de Pós-Graduação em Computação, Diretoria De Pesquisa e Pós-Graduação, Universidade Tecnológica Federal do Paraná, Ponta Grossa, 2019. Disponível em: <http://repositorio.utfpr.edu.br/jspui/handle/1/4038>. Acesso em: 26 mar. 2023.

NELSON, D. M. Q.; PEREIRA, A. C. M.; OLIVEIRA, R. A. Stock market's price

movement prediction with lstm neural networks. **International Joint Conference on Neural Networks (IJCNN)**, Anchorage, p. 1419-1426, 2017. Disponível em: <http://dx.doi.org/10.1109/IJCNN.2017.7966019>. Acesso em: 26 mar. 2023.

O'CONNOR, N.; MADDEN, M. G. A neural network approach to predicting stock exchange movements using external factors. **Knowledge-Based Systems**, Elsevier, v. 19, n. 5, p. 371–378, 2006. Disponível em: <https://doi.org/10.1016/j.knosys.2005.11.015>. Acesso em: 26 mar. 2023.

R Development Core Team. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria, 2009. ISBN 3-900051-07-0. Disponível em: <http://www.R-project.org>. Acesso em: 29 apr. 2023.

ROCHA, H. R. de O. Previsão do Preço de Ações Usando Redes Neurais. *In*: CONGRESSO USP DE INICIAÇÃO CIENTÍFICA EM CONTABILIDADE, 8., 2011, São Paulo. **Anais eletrônicos** [...]. São Paulo: USP, 2011. Disponível em: <https://encurtador.com.br/hosEM>. Acesso em: 26 mar. 2023.

WICKHAM, H.; BRYAN, J.; KALICINSKI, M.; VALERY, K.; Leitienne, C.; COLBERT, B.; HOERL, D.; MILLER, E. **Read Excel Files**. 2023. Disponível em: <https://cran.r-project.org/web/packages/readxl/readxl.pdf>. Acesso em: 26 mar. 2023.