

Análise do Comportamento das Ações do Agronegócio Brasileiro na B3: aplicação de Redes Neurais Artificiais às Variáveis Macroeconômicas (2010-2023)

Analysis of the Behavior of Brazilian Agribusiness Stocks on B3: Application of Artificial Neural Networks to Macroeconomic Variables (2010-2023)

João Bosco Arbués Carneiro Junior^a; Celso Correia de Souza^b; Gisela Maria Jorgino Crespo^b; Raul Asseff Castelão^c; Celso Fabricio Correia de Souza^{bc}

^aUniversidade Federal de Rondonópolis. MT, Brasil.

^bUniversidade Anhanguera Uniderp, Programa de Pós-Graduação em Agronegócio Sustentável. MS, Brasil,

^cUniversidade Anhanguera Uniderp, Programa de Pós-Graduação em Meio Ambiente e Desenvolvimento Regional. MS, Brasil,

*E-mail:

Resumo

Este artigo analisa o comportamento das ações das empresas do agronegócio brasileiro listadas na B3 entre 2010 e 2023, focando na relação com variáveis macroeconômicas como taxa de câmbio, inflação (IPCA), taxa de desocupação, PIB brasileiro e taxa Selic. O estudo visa compreender como essas variáveis impactam o valor das ações, oferecendo informações úteis para investidores e consultores financeiros na gestão de portfólios e na tomada de decisões. A metodologia combina abordagens quantitativas e descritivas. Dados de ações das empresas SLC Agrícola e Brasil Agro foram extraídos de *Yahoo Finance*, enquanto as variáveis macroeconômicas foram obtidas do IBGE e BACEN. O tratamento estatístico foi feito com o software IBM-SPSS 24, permitindo a análise das correlações entre variáveis e a aplicação de Redes Neurais Artificiais (RNA), especificamente o modelo RNA Multilayer Perceptron. Os resultados mostram que o PIB_BRAS é a variável mais importante para prever os valores das ações, com importância de 100%, seguido pela taxa de câmbio com 65,9%. A taxa Selic e o IPCA têm impactos moderados, com importâncias de 20,3% e 15,1%, respectivamente, enquanto a taxa de desocupação é a menos relevante, com 7,3%. A análise de correlação confirmou que o PIB brasileiro e a taxa de câmbio têm correlações positivas significativas com os valores das ações, enquanto a taxa de desocupação e a inflação mostraram correlações mais fracas. O estudo destaca a eficácia das RNA para modelar relações complexas e sugere que a combinação de técnicas estatísticas e aprendizado de máquina é promissora para previsões e estratégias de investimento.

Palavras-chave: Aprendizado de Máquina. Análise do Mercado de Ações. Previsão Financeira. Impacto Macroeconômico. Modelagem Preditiva.

Abstract

This article analyzes the behavior of the stock prices of Brazilian agribusiness companies listed on the B3 between 2010 and 2023, focusing on their relationship with macroeconomic variables such as exchange rate, inflation (IPCA), unemployment rate, Brazilian GDP, and Selic rate. The study aims to understand how these variables impact stock values, providing useful information for investors and financial consultants in portfolio management and decision-making. The methodology combines quantitative and descriptive approaches. Stock data for SLC Agrícola and Brasil Agro were extracted from Yahoo Finance, while macroeconomic variables were obtained from IBGE and BACEN. Statistical treatment was performed using IBM-SPSS 24, enabling the analysis of correlations between variables and the application of Artificial Neural Networks (ANN), specifically the Multilayer Perceptron (MLP) model. Results show that Brazilian GDP is the most important variable for predicting stock values, with an importance score of 100%, followed by the exchange rate at 65.9%. The Selic rate and IPCA have moderate impacts, with values of 20.3% and 15.1%, respectively, while the unemployment rate is the least relevant, with 7.3%. Correlation analysis confirmed that Brazilian GDP and the exchange rate have significant positive correlations with stock values, whereas the unemployment rate and inflation showed weaker correlations. The study highlights the effectiveness of ANN in modeling complex relationships and suggests that the combination of statistical techniques and machine learning is promising for predictions and investment strategies.

Keywords: Machine Learning. Stock Market Analysis. Financial Forecasting. Macroeconomic Impact. Predictive Modeling.

1 Introdução

No contexto do agronegócio brasileiro, as empresas listadas na B3 desempenham um papel significativo não apenas na economia nacional, mas também no mercado global de commodities. A B3, que surgiu da fusão entre a Bolsa de Valores, Mercadorias e Futuros de São Paulo (BM&FBovespa) e a Central de Custódia e de Liquidação Financeira de Títulos (Cetip) em 2017, representa a união de três aspectos fundamentais da economia brasileira: Brasil, Bolsa e Balcão (B3+Agro, 2024).

Ainda, segundo B3+Agro (2024), a B3 tem operações

diversificadas que abrangem desde a produção agrícola até a agroindústria e a distribuição, essas empresas enfrentam um ambiente complexo de variáveis econômicas que impactam diretamente o valor de suas ações no mercado de capitais.

O objetivo deste estudo é analisar o comportamento dos valores das ações das empresas do agronegócio brasileiro listadas na B3 ao longo do período de 2010 a 2023, investigando sua relação com as principais variáveis macroeconômicas brasileiras, como taxa de câmbio, inflação, taxa de desocupação, PIB brasileiro e taxa Selic.

A importância de analisar os valores das ações dessas

empresas na bolsa é significativa, tanto para investidores quanto para consultores financeiros. Para investidores, entender como as flutuações das variáveis macroeconômicas afetam o desempenho das ações pode orientar decisões mais robustas de investimentos e estratégias de alocação de recursos financeiros no mercado de capitais (Planner, 2024). Para consultores financeiros, essas análises proporcionam informações valiosas para a gestão de portfólios e aconselhamento aos clientes, baseadas em evidências empíricas sólidas.

A hipótese central deste estudo é investigar se existe relação significativa entre as variáveis macroeconômicas, como taxa de câmbio, taxa de desocupação, taxa Selic, inflação (IPCA) e PIB brasileiro, e os valores das ações das empresas do agronegócio brasileiro listadas na B3. Este estudo não apenas busca identificar correlações diretas, mas também avaliar o grau de influência de cada variável sobre o comportamento das ações no mercado de capitais.

2 Material e Métodos

Esta pesquisa tem uma abordagem quantitativa, descritiva e documental. A metodologia quantitativa foi empregada para analisar estatísticas descritivas, correlacionar indicadores de desempenho econômico-financeiro com variáveis macroeconômicas e realizar testes de previsão usando RNA. E quanto aos procedimentos trata-se de pesquisa documental, com utilização de banco de dados: *Yahoo Finance*, Instituto Brasileiro de Geografia e Estatística (IBGE) e Banco Central do Brasil (BACEN).

Em virtude da ausência de dados no período de estudo (2010-2023), a amostra é composta somente por duas empresas do agronegócio brasileiro: SLC Agrícola e Brasil Agro, ambas listadas pela B3. Com contribuições significativas para o PIB brasileiro, analisando essas duas empresas é possível compreender o comportamento dos seus indicadores de desempenhos em face à conjuntura macroeconômica. Os valores dos ativos dessas empresas na B3 foram coletados por meio do site *Yahoo Finance* (*Yahoo, Finance*, 2024) e as séries históricas das variáveis macroeconômicas, conforme o Quadro 1, considerando a escala temporal de 2010 a 2023, foram coletadas nas referências do próprio quadro.

Quadro 1 - Variáveis macroeconômicas com siglas e características das variáveis e referências

Variáveis Macroeconômicas	Sigla	Características das Variáveis e Referências
Taxa de Câmbio	CAMB	Taxa média anual dólar comercial para venda expressa em (%) (BACEN, 2024)
Taxa Média de Desocupação	DESOC	Taxa média anual expressa em (%) (IBGE, 2024a)
Taxa Selic Média Anual	SELIC	Taxa média anual expressa em (%) (BACEN, 2024)

Variáveis Macroeconômicas	Sigla	Características das Variáveis e Referências
Inflação	IPCA	Taxa média anual expressa em (%) (IBGE, 2024b)
Produto Interno Bruto do Brasil	PIB_BRAS	Valor corrente anual, em R\$ milhões (IBGE, 2024c)

Fonte: dados da pesquisa.

O banco de dados foi estruturado em planilhas eletrônicas no Excel, e a análise estatística foi conduzida com o software IBM-SPSS, versão 24. A análise envolveu a utilização da correlação de Spearman para examinar as relações entre as variáveis macroeconômicas e os valores das ações das empresas do agronegócio, considerando variáveis não paramétricas. Além disso, foi realizada uma análise detalhada das variáveis macroeconômicas e seu impacto no comportamento dos valores das ações, empregando Redes Neurais Artificiais (RNA), especificamente o modelo *Multilayer Perceptron* (MLP) no IBM-SPSS (IBM-SPSS, 2020).

Nesta seção, ainda serão discutidos conceitos relacionados às ações das empresas do agronegócio brasileiro, negociadas na B3, além das técnicas de Análise de Correlação e Redes Neurais Artificiais. A ênfase será na aplicação dessas técnicas para analisar e entender melhor como as variáveis macroeconômicas influenciam o comportamento das ações de empresas ligadas ao agronegócio brasileiro.

2.1 Bolsa de Valores B3

A B3, principal bolsa de valores do Brasil, sediada em São Paulo, utiliza como referência o índice Ibovespa, calculado pela média ponderada das ações mais negociadas nos últimos meses. A negociação de ações na B3 permite que investidores adquiram participação nas empresas através de seus títulos, o que possibilita às companhias captarem recursos para impulsionar seu crescimento (B3, 2024).

Ainda, segundo B3 (2024), o mercado de ações é conhecido pela sua característica de renda variável, em que o lucro do investidor resulta da diferença entre o preço de compra e venda das ações, com a possibilidade de ganho de capital sujeito à incidência de impostos, além dos dividendos distribuídos pelas empresas. Os acionistas podem possuir ações ordinárias, que garantem direito a voto em assembleias, ou preferenciais, que conferem prioridade no recebimento de dividendos e lucros. A compra de ações pode ser realizada por meio de corretoras de valores ou através de fundos e planos de previdência privada.

As corretoras intermediam as transações na bolsa de valores, sendo remuneradas por taxas de corretagem e de custódia, que cobrem a emissão de relatórios e a custódia dos ativos. As variações nos preços das ações refletem os interesses dos investidores: se a oferta de venda é elevada e a demanda de compra é baixa, os preços tendem a diminuir para atrair compradores; inversamente, quando há mais

interessados em comprar do que vender, os preços sobem, em função da competição entre investidores. Essas flutuações são influenciadas, significativamente, por eventos corporativos e econômicos (Cerbasi, 2020).

Os investidores monitoram de perto as empresas nas quais investem por meio de notícias e análises disponibilizadas pelas corretoras, que podem incluir análises fundamentais, baseadas em aspectos econômicos e financeiros da empresa, e análises técnicas, que utilizam o histórico de preços das ações e as flutuações das variáveis macroeconômicas para prever tendências futuras.

2.2 Análise de correlação

A análise de correlação é uma técnica estatística fundamental para examinar a relação entre duas ou mais variáveis, permitindo entender como uma variável pode estar associada com a outra. A correlação mede a força e a direção da relação linear entre variáveis, fornecendo um coeficiente que varia de -1 a +1. Um coeficiente próximo de +1 indica forte correlação positiva, na qual ambas as variáveis tendem a aumentar ou diminuir juntas. Um coeficiente próximo de -1 sugere forte correlação negativa, em que uma variável tende a aumentar enquanto a outra diminui. Um coeficiente próximo de zero indica fraca ou nenhuma correlação (Hair *et al.*, 2009).

Ainda, segundo Hair *et al.* (2009), a análise de correlação é amplamente utilizada em diversas áreas, como finanças, saúde e Ciências Sociais, para explorar e identificar padrões nas relações entre variáveis. Métodos comuns incluem a correlação de Pearson, que avalia relações lineares entre variáveis contínuas, e a correlação de Spearman, adequada para variáveis ordinais ou quando a relação não é linear (não paramétricas). Essas análises são importantes para a modelagem de dados, previsão e tomada de decisões, pois ajudam a identificar e quantificar a força das associações entre variáveis, fornecendo informações valiosas sobre os dados e suas interações.


2.3 Redes Neurais Artificiais (RNA)

As Redes Neurais Artificiais (RNA) são um campo essencial dentro da Inteligência Artificial (IA), que visa emular o funcionamento do cérebro humano, incluindo sua capacidade de aprendizado, adaptação e tomada de decisão. Inspiradas na estrutura e funcionamento dos neurônios biológicos, as RNA têm sido amplamente utilizadas para resolver uma variedade de problemas complexos, desde o reconhecimento de padrões até a previsão de séries temporais e a tomada de decisões em tempo real (Haykin, 2009).

Conforme Barber (2012), as RNA são sistemas computacionais compostos por unidades de processamento interconectadas, conhecidas como neurônios artificiais ou nodos. Cada neurônio artificial recebe uma ou mais entradas, realiza operações de processamento e gera uma saída, que pode ser utilizada como entrada para outros neurônios na rede.

A interconexão entre os neurônios é estabelecida por meio de pesos sinápticos, que indicam a força e a direção da influência de cada entrada na saída do neurônio. O funcionamento de um neurônio artificial é análogo ao de um neurônio biológico, Figura 1, em que as entradas correspondem aos sinais recebidos pelos dendritos, o processamento ocorre no corpo celular e a saída é transmitida através do axônio.

Figura 1 - Representação de um neurônio biológico evidenciando seus principais elementos

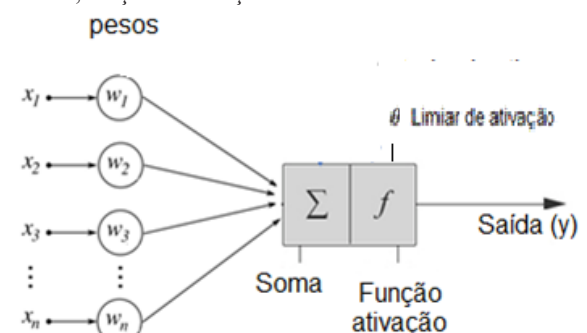


Fonte: Google (2024).

O neurônio biológico, conforme a Figura 1, é um componente fundamental do sistema nervoso, possuindo uma estrutura formada por dendritos, soma e axônio. Os dendritos recebem estímulos elétricos de outros neurônios, conduzindo-os ao corpo celular, em que são processados até atingirem um limiar de excitação. Uma vez que este limiar é alcançado, um impulso elétrico é gerado pelo axônio, transmitindo os estímulos para outros neurônios e para as terminações sinápticas. As sinapses, que são as conexões entre neurônios, permitem a transferência de impulsos elétricos através da liberação de neurotransmissores, sem que haja contato físico direto (Carneiro Júnior; Souza, 2019).

A principal diferença entre o neurônio biológico para o neurônio artificial está na simplicidade dos neurônios artificiais, facilitando a modelagem matemática desse. As descrições do modelo matemático de um neurônio biológico resultaram em um modelo de neurônio artificial, em função de McCulloch e Pitts (1943), representado na Figura 2, composto de terminais de entrada (dendritos) e o corpo de neurônios representado pela soma e função de ativação e do axônio, representada na saída y .

Figura 2 - Modelo de um neurônio artificial com os terminais de entrada, função de ativação e saída



Fonte: adaptado de Barber (2012).

A saída de um neurônio artificial é dada por sendo u uma combinação linear dos parâmetros obtidos a partir da função soma do neurônio artificial, equação (1).

$$u = \sum_{i=1}^n w_i x_i - \theta = w_1 x_1 + w_2 x_2 + \dots + w_n x_n - \theta \quad 01$$


O valor de u aumenta até atingir o limiar de excitação, e produz a função de ativação na saída, descarregando até atingir valores muito próximos de zero, e o processo se repete (Haykin, 2009).

2.4 Arquiteturas e Topologias das Redes Neurais

As RNA podem ser organizadas em diversas arquiteturas, cada uma com suas características específicas. Entre as mais comuns estão as redes *feedforward*, nas quais a informação flui em uma única direção, das camadas de entrada às camadas de saída. Além disso, as redes recorrentes, que possuem conexões cíclicas entre neurônios, permitem a *feedback* de informações ao longo do tempo. Vale destacar que as RNA podem ter várias camadas de neurônios, configurando-se como redes multicamadas (MLP), o que possibilita a modelagem de padrões mais complexos e a captura de relações não-lineares entre os dados (Braga *et al.*, 2014).

A Figura 3 ilustra a estrutura típica de uma rede neural multicamadas (RNA_MLP).

Figura 3 - Estrutura de uma RNA_MLP com a representação da camada de entrada, duas camadas intermediárias e de uma camada de saída



Fonte: adaptada de Barber (2012).

2.5 Algoritmos de Treinamento das Redes Neurais

Segundo Carneiro Júnior e Souza (2019), o treinamento das RNA implica ajustar os pesos sinápticos e os limiares dos neurônios para permitir que a rede aprenda e generalize a partir dos dados de entrada. Diversos algoritmos de treinamento estão disponíveis na literatura, cada um apresentando vantagens e limitações específicas. Os principais métodos incluem o treinamento supervisionado, em que a rede é treinada com pares de entrada e saída conhecidos, o treinamento não supervisionado, que utiliza apenas os dados de entrada; e o treinamento por reforço, em que a rede aprende através de tentativa e erro, recebendo feedback do ambiente.

A arquitetura da RNA_MLP utilizada neste trabalho é do tipo *feedforward*, utilizando o método de treinamento supervisionado com retropropagação do erro. A escolha da topologia da rede depende da natureza do problema a ser tratado, da distribuição espacial das amostras de treinamentos e dos valores iniciais dos parâmetros e pesos (Smith, 2018).

2.6 Treinamento Backpropagation

O algoritmo de retropropagação, também conhecido como regra Delta Generalizada, foi crucial para o renascimento do interesse em RNA, pois, durante a década de 1970 e início dos anos 1980, as RNA enfrentaram um período de desinteresse significativo na comunidade científica. Este declínio no entusiasmo pode ser atribuído a várias razões, incluindo a limitação das técnicas de treinamento disponíveis na época e a falta de capacidade computacional.

Esse algoritmo supervisionado de retropropagação ajusta os pesos da rede com base em pares de entrada e saída desejada, por meio de um processo de correção de erros. O treinamento do modelo é realizado em duas etapas: a fase *forward* e a fase *backward*. Na fase *forward*, a rede processa um conjunto de entradas para calcular a saída desejada, ao mesmo tempo em que atualiza os pesos das conexões entre os neurônios, enquanto os pesos sinápticos e os limiares dos neurônios permanecem inalterados. Na fase *backward*, o erro é retropropagado, ajustando os pesos sinápticos e limiares em resposta ao erro calculado ao longo da rede (Braga *et al.*, 2014).

Segundo Safi e Bourroum (2011), o treinamento de uma RNA pode ser descrito em etapas distintas: i) Selecionar um par do conjunto de treinamento e aplicar o vetor de entrada à rede: Escolhe-se um exemplo específico do conjunto de dados de treinamento, que inclui um vetor de entrada e a saída esperada correspondente; ii) Calcular a saída da rede: A rede processa o vetor de entrada através das camadas de neurônios e gera uma saída com base nas ativações dos neurônios; iii) Calcular o erro entre a saída da rede e a saída-alvo: A diferença entre a saída gerada pela rede e a saída esperada (ou alvo) é calculada para determinar o erro; iv) Ajustar os pesos da rede de maneira a minimizar o erro: Os pesos das conexões entre os neurônios são ajustados usando algoritmos de otimização, como o gradiente descendente, para reduzir o erro calculado e ; v) Repetir o processo para cada vetor do conjunto de treinamento. O ciclo é repetido para todos os vetores do conjunto de treinamento até que o erro global da rede se torne suficientemente baixo e aceitável para todo o conjunto de dados. Desse modo, essas etapas são realizadas iterativamente até que o modelo aprenda a prever as saídas corretas com precisão suficiente.

2.7 Redes Neurais Artificiais e Previsão Financeira

As RNA têm se mostrado extremamente eficazes na análise do comportamento das ações, especialmente, quando integradas com variáveis macroeconômicas como taxa de

câmbio, inflação, taxa de desocupação, PIB brasileiro e taxa Selic. De acordo com Zhang *et al.* (2001), as RNA são capazes de modelar padrões complexos e não-lineares, capturando a interação intrincada entre essas variáveis e o desempenho das ações. Esse poder de modelagem permite que as RNA se adaptem às mudanças econômicas e forneçam previsões precisas, mesmo em mercados voláteis.

Além disso, como ressaltado por LeCun *et al.* (2015), a capacidade das RNA de ajustar os pesos das conexões com base em dados históricos e *feedback* contínuo melhora sua eficiência na identificação de padrões e tendências. Assim, as RNA oferecem uma ferramenta robusta para investidores e analistas financeiros, ajudando a entender o impacto das variáveis macroeconômicas no mercado de ações e a tomar decisões estratégicas informadas.

3 Resultados e Discussão

As séries históricas de dados sobre as ações das duas empresas agropecuárias listadas na B3 foram coletadas do site Yahoo!Finance, em que os dados de cada empresa foram registrados em planilhas Excel para posterior análise. A coleta compreendeu o período de janeiro de 2010 a dezembro de 2023, totalizando 14 informações para cada empresa analisada (Yahoo!Finance, 2024).

O Quadro 1 oferece uma visão abrangente dos índices macroeconômicos Taxa de Câmbio (CAMB), Taxa de Desocupação (DESOC), Taxa de Juros (SELIC), Taxa de Inflação (IPCA) e Produto Interno Bruto do Brasil (PIB_BRAS), obtidas dos bancos de dados (Bacen, 2024; Bovespa, 2024; IBGE, 2024abc), bem como os preços das ações das duas empresas agropecuárias listadas na B3, SLC Agrícola e Brasil Agro, no período analisado.

Quadro 1 - Índices macroeconômicos CAMB, DESOC, SELIC, IPCA, PIB_BRAS e os preços das ações das duas empresas SLC Agrícola e Brasil Agro, no período de 2010 a 2023

Ano	CAMB (R\$/USD\$)	DESOC (%)	SELIC (%)	IPCA (%)	PIB_BRAS (R\$ $\times 10^6$)	SLC Agrícola (R\$)	Brasil Agro (R\$)
2010	1,6654	6,70	10,75	5,91	3886,00	4,52	11,00
2011	1,8751	6,00	11,00	6,50	4376,00	3,20	9,74
2012	2,0429	7,40	7,25	5,84	4814,00	4,10	10,00
2013	2,342	7,30	10,00	5,91	5331,00	4,21	9,45
2014	2,6556	7,00	11,75	6,41	5779,00	2,91	9,09
2015	3,9042	8,90	14,25	10,67	5996,00	3,40	11,03
2016	3,2585	11,70	13,75	6,29	6267,00	2,99	11,04
2017	3,3074	12,60	7,00	2,95	6554,00	5,51	12,52
2018	3,8742	12,20	6,50	3,75	6827,00	8,65	15,61
2019	4,0301	11,80	4,50	4,31	7389,00	10,25	19,02
2020	5,1961	13,80	2,00	4,52	7610,00	11,34	25,00
2021	5,5799	14,00	9,25	10,06	8679,00	19,04	28,96
2022	5,2171	9,60	13,75	5,79	9900,00	20,88	30,20
2023	4,8407	7,80	11,75	4,62	10900,00	18,82	26,71

Fonte: dados da pesquisa.

A análise do Quadro 1, de índices macroeconômicos e preços das ações de SLC Agrícola e Brasil Agro entre 2010 e 2023, revelam várias tendências significativas. O câmbio brasileiro passou de 1,6654 R\$/USD\$ em 2010 para 4,8407 R\$/USD\$ em 2023, indicando desvalorização do real frente ao dólar ao longo dos anos. A taxa de desemprego apresentou aumento notável, especialmente entre 2015 e 2016, refletindo a crise econômica do período. A taxa Selic variou consideravelmente, atingindo um pico em 2015 (14,25%) e caindo para 2,00% em 2020, seguida por novo aumento em 2021. A inflação, medida pelo IPCA, foi relativamente estável até 2015, mas subiu em 2016 e 2021, sinalizando desafios econômicos. O PIB brasileiro, por sua vez, cresceu de 3.886 milhões de R\$ em 2010 para 10.900 milhões de R\$ em 2023, apesar das flutuações ao longo do período.

Os preços das ações da SLC Agrícola aumentaram, substancialmente, subindo de 4,52 R\$ em 2010 para 18,82 R\$ em 2023, com picos significativos em 2021 e 2022. A Brasil Agro teve um crescimento mais moderado, com suas

ações indo de 11,00 R\$ para 26,71 R\$ em 2023, indicando um desempenho sólido no setor agrícola.

A relação entre os indicadores sugere que o aumento no preço das ações das empresas coincide com períodos de crescimento do PIB brasileiro, destacando uma conexão positiva entre o desempenho econômico e o setor agrícola. A queda da Selic em 2020 e 2021, provavelmente, estimulou investimentos nas empresas, refletindo-se no aumento dos preços das ações. Com a inflação sob controle e o PIB brasileiro crescente, as perspectivas para SLC Agrícola e Brasil Agro são positivas, evidenciando a importância do agronegócio no Brasil.

Em decorrência do número limitado de dados coletados, apenas 14 observações para cada variável, não foi possível realizar previsões com base nesses dados. Como resultado, a análise preditiva está fora do escopo deste artigo. O Quadro 2 apresenta a matriz de correlações entre os índices macroeconômicos CAMB, DESOC, SELIC, IPCA, PIB_BRAS, bem como com os valores das ações das empresas SLC Agrícola e Brasil Agro, no período de 2020 a 2023.

Quadro 2 - Matriz de Correlações de Spearman entre os Índices Macroeconômicos CAMB, DESOC, SELIC, IPCA, PIB_BRAS, bem como com os Valores das Ações das Empresas SLC Agrícola e Brasil Agro, no Período de 2020 a 2023.

	CAMB	DESOC	SELIC	IPCA	PIB_BRAS	SLC Agrícola	Brasil Agro
CAMB	1,000						
DESOC	0,745	1,000					
SELIC	-0,079	-0,469	1,000				
IPCA	-0,180	-0,407	0,639*	1,000			
PIB_BRAS	0,916	0,710	-0,101	-0,383	1,000		
SLC Agrícola	0,749	0,578	-0,339	-0,466	0,789	1,000	
BRASIL Agro	0,908	0,727	-0,156	-0,378	0,903	0,890	1,000

Fonte: saída do IBM-SPSS 24.

A análise do Quadro 2 é fundamental aos investidores e tomadores de decisões, pois permite identificar as inter-relações entre variáveis macroeconômicas e o desempenho das ações das empresas do setor agrícola. Compreender essas correlações ajuda investidores e gestores a tomar decisões mais informadas, avaliando como fatores macroeconômicos, como o câmbio e a inflação, impactam o mercado agrícola. Além disso, essa análise pode revelar oportunidades de investimento e riscos associados a mudanças nas condições econômicas, contribuindo para estratégias mais robustas no setor. Portanto, calcular a matriz de correlação não apenas enriquece a compreensão do ambiente econômico, mas também é essencial para otimizar a performance financeira das empresas agrícolas em um contexto dinâmico e desafiador.

O Quadro 2 também revela que o câmbio (CAMB) mostra uma correlação positiva significativa com o PIB_BRAS (0,916) e com os preços das ações da Brasil Agro (0,908), indicando que a desvalorização do real pode estar associada ao aumento nos preços das ações dessas empresas, embora a correlação com a SLC Agrícola seja um pouco menor (0,749). A taxa de desemprego (DESOC) apresenta correlações positivas moderadas com ambas as empresas, sendo 0,578 para SLC Agrícola e 0,727 para Brasil Agro. Isso sugere que, em tempos de crise, quando o desemprego aumenta, os preços das ações dessas empresas tendem a subir, possivelmente devido a uma maior demanda por produtos agrícolas. Por outro lado, a taxa Selic tem uma correlação negativa com os preços das ações, com valores de -0,339 para SLC Agrícola e -0,156 para Brasil Agro, indicando que altas taxas de juros podem impactar negativamente os preços das ações, refletindo um ambiente menos favorável para investimentos.

A inflação (IPCA) também apresenta correlações negativas com os preços das ações, sendo -0,466 para SLC Agrícola e -0,378 para Brasil Agro. Isso sugere que aumentos na inflação podem afetar adversamente o valor das ações, possivelmente, em função de custos crescentes e redução do poder de compra dos consumidores. Em contraste, o PIB_BRAS demonstra correlações positivas e significativas com ambas as empresas, com 0,789 para SLC Agrícola e 0,903 para Brasil Agro, indicando que o crescimento econômico está associado ao aumento dos preços das ações, ressaltando a importância do agronegócio na economia brasileira.

Em resumo, a análise das correlações sugere que fatores

como câmbio e PIB_BRAS têm relação positiva com os preços das ações de SLC Agrícola e Brasil Agro, enquanto altas taxas de desemprego e inflação tendem a impactar negativamente. A taxa Selic também exerce uma influência negativa, destacando a necessidade de um ambiente econômico estável para o crescimento do setor agrícola.

Como o objetivo deste estudo é o de analisar o comportamento dos valores das ações das empresas do agronegócio brasileiro listadas na B3, ao longo do período de 2010 a 2023, investigando sua relação com as principais variáveis macroeconômicas, visando fornecer informações precisas para investidores e consultores no mercado financeiro, aplicaremos conceitos de RNA_MLP. Esse método permitirá modelar relações complexas entre as variáveis macroeconômicas e os preços das ações, contribuindo para uma melhor tomada de decisão.

Utilizando os dados do Quadro 1, em que as variáveis macroeconômicas representam as variáveis independentes e os valores das ações das duas empresas agropecuárias são as variáveis dependentes, obteve-se o resumo do processamento dos casos da RNA_MLP aplicada. No total, foram analisadas 14 amostras, das quais 8 (57,1%) foram utilizadas para treinamento e 6 (42,9%) para testes. Todos os 14 casos foram considerados válidos, pelo fato de não haver amostras excluídas.

A estrutura da RNA_MLP utilizada apresentou na camada de entrada as cinco variáveis macroeconômicas: CAMB, IPCA, DESOC, PIB_BRAS e SELIC. Essas variáveis foram padronizadas no sentido de melhorar a convergência do modelo. A rede possui uma única camada oculta com três unidades, utilizando a função de ativação tangente hiperbólica, que é eficaz para modelar não linearidades nos dados. A camada de saída constou das duas variáveis dependentes: Brasil Agro e SLC Agrícola, também padronizadas e a função de ativação utilizada é a identidade, apropriada para problemas de regressão, como esse que se apresenta. O erro é avaliado pela soma dos quadrados, o que permite otimizar o ajuste do modelo. Essa configuração permite capturar relações complexas não lineares entre as variáveis macroeconômicas e os resultados desejados no setor agropecuário. A Figura 4 resume a estrutura da Rede Neural MLP utilizada no estudo.

Figura 4 - Resumo da estrutura da Rede Neural MLP utilizada no estudo

Camada de entrada		1	Taxa de Câmbio	
		2	Inflação (IPCA)	
	Covariáveis*	3	Taxa de Desocupação	
		4	Produto Interno Bruto	
		5	Taxa Selic	
	Número de unidades**			5
	Método de reescalonamento para covariáveis		Padronizado	
Camadas ocultas	Número de camadas ocultas			1
	Número de Unidades na Camada Oculta			3
	Função de ativação		T a n g e n t e hiperbólica	
	Variáveis dependentes	2	Brasil Agro	
			SLC Agrícola	
Camada de saída	Número de unidades			2
	Método de reescalonamento para dependentes de escala		Padronizado	
	Função de ativação		Identidade	
	Função de erro		Soma Quadrados	

*: Variáveis de entrada; **: Excluindo a unidade de viés.

Fonte: saída do IBM-SPSS 24.

A Figura 4 apresenta o resumo do modelo de rede neural com foco nas variáveis macroeconômicas relacionadas ao Brasil, como taxa de câmbio, inflação, taxa de desocupação, PIB brasileiro e taxa Selic. O modelo possui uma camada de entrada com cinco covariáveis padronizadas, uma única camada oculta com três unidades utilizando a função de ativação tangente hiperbólica, e uma camada de saída com duas variáveis dependentes, “Brasil Agro” e “SLC Agrícola”, também padronizadas. A função de ativação da camada de saída é a identidade, e a soma dos quadrados é empregada como função de erro para otimizar o desempenho da rede.

A sumarização do modelo revela um desempenho robusto durante o treinamento e testes. A soma dos erros quadráticos durante o treinamento foi de 0,347, com um erro relativo geral médio de 0,050. Especificamente, o erro relativo para “Brasil Agro” foi 0,024 e para “SLC Agrícola” foi 0,075. O modelo foi treinado rapidamente, com um tempo próximo de zero, utilizando uma regra de parada de um passo consecutivo sem diminuição dos erros. Nos testes, a soma dos erros quadráticos reduziu-se para 0,110, com um erro relativo geral médio de 0,014, indicando melhor desempenho. Os erros relativos para as variáveis dependentes foram 0,012 para “Brasil Agro” e 0,015 para “SLC Agrícola”.

A interpretação dos resultados pelas estimativas dos parâmetros mostra que, entre as variáveis macroeconômicas, o PIB brasileiro exerce a influência mais significativa sobre os valores das ações da LSC Agrícola e Brasil Agro, com um coeficiente de 1,323. O Dólar também tem impacto

considerável, especialmente para Brasil Agro, com coeficiente de 1,064. Em contraste, o IPCA e a Selic apresentam efeitos negativos, com o IPCA mostrando influência desfavorável em ambas as ações. A Selic também contribui negativamente, refletindo impacto desfavorável nos valores das ações. A Taxa Média de Desocupação tem efeito positivo, mas menos pronunciado em comparação com o PIB brasileiro e o Dólar. Em resumo, o PIB brasileiro e o Dólar são as variáveis mais importantes para explicar as flutuações nos valores das ações analisadas.

Por outro lado, observou-se que os gráficos de valores preditos versus valores reais de SLC Agrícola e Brasil Agro se aproximam de uma linha reta, o que indica que a RNA está fazendo previsões precisas e que o modelo está bem ajustado. Isso é confirmado pelas análises dos gráficos dos resíduos versus variáveis dependentes SLC Agrícola e Brasil Agro, que não apresentam leis de formações definidas. A ausência de padrões sistemáticos sugere que os resíduos estão distribuídos aleatoriamente, indicando que o modelo está capturando eficazmente as relações subjacentes sem deixar padrões nos erros.

Para compreender o impacto das variáveis macroeconômicas no comportamento das ações dessas duas empresas, é fundamental analisar a importância relativa de cada variável independente. O Quadro 3 apresenta a importância de cada variável independente no comportamento das ações das empresas SLC Agrícola e Brasil Agro.

Quadro 3 - Importância das variáveis independentes no comportamento das ações das empresas SLC Agrícola e Brasil Agro

Variáveis independentes	Importância	Importância Normalizada
Taxa de Câmbio	0,316	65,9%
Inflação – IPCA	0,072	15,1%
Taxa de Desocupação	0,035	7,3%
Produto Interno Bruto	0,479	100,0%
Taxa Selic	0,097	20,3%

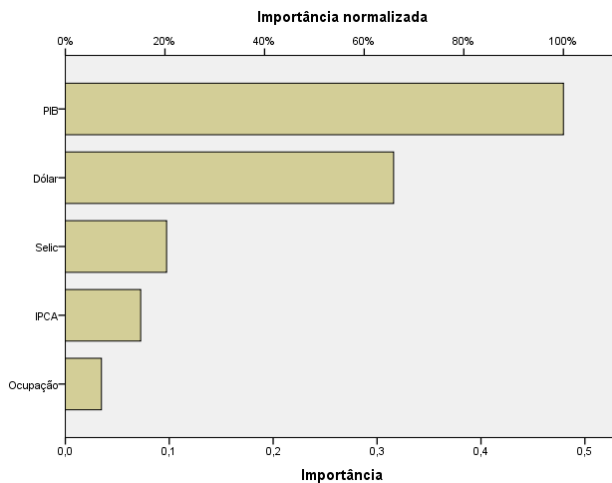
Fonte: saída do IBM-SPSS 24.

A análise do Quadro 3, das variáveis independentes, revela que o Produto Interno Bruto (PIB_BRAS) é a variável mais influente nas ações das empresas SLC Agrícola e Brasil Agro, com uma importância de 0,479, equivalente a 100,0% da importância normalizada. A Taxa de Câmbio também desempenha um papel significativo, com uma importância de 0,316 e 65,9% na importância normalizada, indicando sua forte influência sobre as variáveis analisadas. A Taxa Selic tem impacto relevante, representando 20,3% da importância normalizada com coeficiente de 0,097. Por outro lado, a Inflação (IPCA) e a Taxa de Desocupação têm importâncias menores, com 15,1% e 7,3%, respectivamente. Esses resultados ajudam a identificar quais variáveis macroeconômicas são mais críticas para entender o comportamento das ações analisadas.

A inclusão da Figura 5, com um gráfico para representar os dados do Quadro 3 facilitará a visualização e a comparação

das importâncias das variáveis independentes. O gráfico da Figura 5 ajudará a identificar claramente as influências relativas de cada variável sobre as ações.

Figura 5 - Importância relativa das variáveis macroeconômicas no comportamento das ações das empresas SLC Agrícola e Brasil Agro, no período de 2010 a 2023



Fonte: saída do IBM-SPSS 24.

O gráfico da Figura 5 facilita a visualização e comparação das importâncias relativas de cada variável macroeconômica, oferecendo uma representação clara das contribuições de cada fator no comportamento das ações. Esse permite identificar rapidamente quais variáveis têm maior impacto, simplificando a interpretação dos dados. Com isso, a análise se torna mais acessível e intuitiva, melhorando a compreensão dos resultados.

4 Conclusão

Este estudo analisou o impacto das variáveis macroeconômicas sobre os valores das ações das empresas do agronegócio brasileiro, especificamente SLC Agrícola e Brasil Agro, usando Redes Neurais Artificiais (RNA) para modelar e prever esses efeitos. Os resultados indicam que o Produto Interno Bruto brasileiro é a variável mais relevante, com uma importância de 100,0%, destacando-se como o fator mais significativo na previsão dos valores das ações. A Taxa de Câmbio também é crucial, com uma importância de 65,9%, refletindo sua forte influência no mercado. Em contraste, a Taxa Selic e a Inflação (IPCA) têm impacto moderado, com importâncias de 20,3% e 15,1%, respectivamente. A Taxa de Desocupação mostra a menor relevância, com apenas 7,3%.

A análise das correlações entre as variáveis macroeconômicas e os valores das ações reforça essas conclusões. As correlações evidenciam que o PIB brasileiro e a Taxa de Câmbio possuem correlações positivas significativas com as ações das empresas, corroborando a importância elevada dessas variáveis identificadas pelas RNA_MLP. A Taxa Selic também demonstra uma correlação considerável, alinhando-se com sua importância intermediária. Por outro lado, a Taxa de Desocupação e a Inflação (IPCA) apresentaram

correlações mais fracas com as ações, o que reflete sua menor influência relativa.

Esses achados mostram que tanto a análise de correlações quanto a modelagem por RNA fornecem uma visão consistente sobre as variáveis mais impactantes. A metodologia empregada não só confirma a importância das variáveis identificadas, mas também destaca a eficácia das RNA na captura de relações complexas e interdependentes. O potencial dessa abordagem é significativo, pois pode ser adaptado a outros setores e mercados financeiros para análises detalhadas e previsões precisas. A combinação de técnicas estatísticas e modelos de aprendizado de máquina oferece uma compreensão abrangente dos fatores que afetam o mercado, fornecendo uma base sólida para futuras pesquisas e estratégias de investimento.

Referências

- BACEN - Banco Central do Brasil. Dólar comercial (venda e compra) - cotações diárias. Disponível em: <https://dadosabertos.bcb.gov.br/dataset/dolar-americano-usd-todos-os-boletins-diarios>. Acesso em: 13. ago. 2024.
- BARBER, D.; SOLLICH, P.; SAAD, D. Finite Size Effects in on-line learning of multi-layer Neural Network. In: ELLACOTT, S.W.; MASON, J.C.; ANDERSON, I.J. Mathematics of Neural Networks: Models, Algorithms and Applications. Manchester: SPRINGER SCIENCE, 2012. p.84-88.
- B3+AGRO. Produtos da B3 para o Agro. Disponível em: https://www.b3.com.br/pt_br/b3-agro/. Acesso em: 8. jul. 2024.
- B3. BRASIL – Bolsa – Balcão. Metodologia do Índice Bovespa (Ibovespa). Disponível em: https://www.b3.com.br/data/files/9C/15/76/F6/3F6947102255C247AC094EA8/IBOV-Metodologia-pt-br_Novo_.pdf. Acesso em: 8. jul. 2024.
- BOVESPA – Bolsa de Valores de São Paulo. Cotação de Ações. Disponível em: <https://br.financas.yahoo.com/quote/%5EBVSP/components?p=%5EBVSP>. Acesso em 1 ago.2024.
- BRAGA, A.P.; CARVALHO, A.P.L.F.; LUDERMIR, T.B. Redes neurais artificiais: teoria e aplicações. Rio de Janeiro: LTC, 2014.
- CARNEIRO JÚNIOR, J.B.A.; SOUZA, C.C. Aplicação de redes neurais artificiais na previsão do produto interno bruto do Mato Grosso do Sul em função da produção de cana-de-açúcar, açúcar e etanol. Rev Iberoam. Ciênc. Amb., v.10, n.5, p.218-230. 2019. doi: 10.6008/CBPC2179-6858.2019.005.0019.
- CERBASI, G. Investimentos Inteligentes: estratégias para multiplicar seu patrimônio com segurança e eficiência. Rio de Janeiro: Sextante, 2020.
- GOOGLE. Representação de um neurônio biológico. Disponível em: https://www.researchgate.net/figure/Figura-1-Representacao-de-um-neuronio-biologico_fig1_332948161. Acesso em: 13. ago. 2024.
- HAIR JR. et al. Multivariate data analysis. Upper Saddle River: Printice Hall, 2009.
- HAYKIN, S. Neural networks and learning machines. São Paulo: Pearson, 2009.
- IBGE. Desemprego 2024a. Disponível em: <https://www.ibge.gov.br/explica/desemprego.php>. Acesso em: 13 ago. 2024.
- IBGE. IPCA - Índice Nacional de Preços ao Consumidor Amplo. 2024b. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/precos-e-custos/9256-indice-nacional-de-precos-ao>

- consumidor-amplo.html. Acesso em: 13.ago.2024.
- IBGE. Produto Interno Bruto – PIB. 2024c. Disponível em: <https://www.ibge.gov.br/explica/pib.php>. Acesso em: 13. ago. 2024.
- IBM SPSS. Statistics for Windows. Version 24.0. Armonk, São Paulo. 2020.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v.521, n.7553, p.436-444, 2015.
- McCULLOC, W.; PITTS, W. A logical calculus of ideas iminente in nervous activity. *Bull. Mathem. Biophys.*, v.5, 1990.
- PLANNER. A Importância da Bolsa de Valores para os Investidores nas Empresas e o Brasil. 2024. Disponível em: <https://www.planner.com.br/2020/07/02/a-importancia-das-bolsas-de-valores-para-os-investidores-as-empresas-e-o-brasil/>. Acesso em: 8. jul. 2024.
- SAFI, Y.; BOUROUMI, A. A Neural Network Approach for Prediting Forest Fires. In: IEEE SENSORS, Morocco. Conference IEEE Sensors. Morocco: IEEE, 2011.
- SMITH, J. Arquitetura de redes neurais MLP e a retropropagação do erro. *J. Neural Networks*, v.15, n.3, p.45-60, 2018.
- YAHOO!FINANCE. BOVESPA. 2024. Disponível em: <https://br.financas.yahoo.com/noticias/brasil/>. Acesso em: 13.ago.2024.
- ZHANG, G.; PATUWO, B.E.; HU, M.Y. A simulation study of artificial neural networks for forecasting time series. *Comp. Oper. Res.*, v.22, n.6, p.435-444, 2001.