

PREVISÃO DE PREÇO DE ALIMENTOS UTILIZANDO O MÉTODO ARIMA E INTELIGÊNCIA ARTIFICIAL

FOOD PRICE FORECAST USING THE ARIMA METHOD AND ARTIFICIAL INTELLIGENCE

Leonardo Scodro*  E-mail: lscodro@ucs.br

Leandro Luis Corso*  E-mail: lcorso@ucs.br

*Universidade de Caxias do Sul (UCS), Caxias do Sul, RS, Brasil.

Resumo: A previsão dos preços dos alimentos desempenha um papel essencial na gestão da segurança alimentar, uma vez que permite aos governos e às empresas planejarem a oferta e procura, com o objetivo de prevenir instabilidade no mercado e assegurar a população tenha acesso aos alimentos. Uma forma considerada eficaz de obter previsões dos preços dos alimentos é por meio da aplicação de métodos de análise de séries temporais, como o modelo Autoregressive Integrated Moving Average (ARIMA), juntamente com técnicas de inteligência artificial. Neste artigo foi realizado uma previsão de preços pagos a produtores pela hortaliça cenoura na cidade de Caxias do Sul, tendo como base de dados o histórico das cotações de 2016 a 2021. Foi verificado também, uma possível relação entre os índices pluviométricos da região e a variação no preço do legume por meio dos métodos de correlação de Pearson e Spearman. Para realizar as previsões foram utilizados dois métodos o (ARIMA) e Redes Neurais Artificiais (RNA). A assertividade das previsões foi mensurada por meio de dois erros: Erro Percentual Absoluto Médio (MAPE) e Erro Médio Absoluto (MAE). Na comparação entre as previsões o método de inteligência artificial RNA se mostrou mais confiável com MAPE de 13,95% enquanto que o ARIMA obteve uma acuracidade de 21,75% nas previsões dos preços de 2021.

Palavras Chave: Previsão de Preço. Alimentos. Cenoura. ARIMA. RNA.

Abstract: The prediction of food prices plays a crucial role in food security management as it enables governments and businesses to plan supply and demand, aiming to prevent market instability and ensure access to food for the population. One effective way of obtaining food price forecasts is through the application of time series analysis methods, such as the Autoregressive Integrated Moving Average (ARIMA) model, along with artificial intelligence techniques. In this article, a forecast of prices paid to producers for the vegetable carrot in the city of Caxias do Sul was conducted, based on the historical quotations from 2016 to 2021. Additionally, a possible relationship between rainfall indices in the region and the variation in vegetable prices was examined using Pearson and Spearman correlation methods. Two methods were used for the forecasts: ARIMA and Artificial Neural Networks (ANN). The accuracy of the forecasts was measured using two error metrics: Mean Absolute Percentage Error (MAPE) and Mean Absolute Error (MAE). In the comparison between the forecasts, the artificial intelligence method ANN proved to be more reliable, with a MAPE of 13.95%, while ARIMA achieved an accuracy of 21.75% in the price forecasts for 2021.

Keywords: Price Forecast. Carrot. Food. ARIMA. RNA.

1 INTRODUÇÃO

Segundo cálculos da Confederação da Agricultura e Pecuária do Brasil (CNA, 2021), o Produto Interno Bruto (PIB) do agronegócios brasileiro, em 2020, quase chegou a marca de R\$ 2 trilhões, representando aproximadamente 26,6% do PIB brasileiro. Dentre diversos fatores que impulsionaram o crescimento do setor, fica evidente os altos preços das commodities agrícolas ocasionados pela diminuição da oferta mundial devido a pandemia da Covid-19. Entretanto, de acordo com o Centro de Estudos Avançados em Economia Aplicada (Cepea) da Esalq/USP, em colaboração com a Confederação da Agricultura e Pecuária do Brasil (CNA), o Produto Interno Bruto (PIB) do setor agropecuário brasileiro teve um modesto aumento de 0,34% no último trimestre de 2022. A alta vem após três trimestres consecutivos de queda. Apesar do desempenho deste trimestre, os números do final do ano mostram uma queda significativa, com uma redução de 4,22% no PIB acumulado (Confederação da Agricultura e Pecuária do Brasil, 2023).

O Brasil é reconhecido como um grande produtor agrícola, reconhecido por seus impressionantes níveis de produtividade e produção de alta qualidade. No entanto, o país enfrenta desafios significativos em relação às perdas que ocorrem em todas as etapas da cadeia produtiva.

A prevalência de grandes perdas de alimentos no setor de hortifrutigranjeiros, popularmente chamados de hortifrútis, que inclui frutas e legumes, é evidente ao longo de todo o processo de produção. Este problema é particularmente acentuado entre os pequenos agricultores familiares, que normalmente operam com recursos financeiros e tecnológicos limitados. As perdas podem ocorrer em todas as etapas da cadeia produtiva, desde o plantio e a colheita, passando pelo transporte e armazenamento, e culminando nos processos de distribuição e venda ao consumidor ou durante a industrialização (Corrêa, 2019).

De acordo com o relatório do Índice de Desperdício Alimentar divulgado pelo Programa das Nações Unidas para o Ambiente (PNUA), estima-se que 931 milhões de toneladas de alimentos vendidos para residências, varejistas, restaurantes e outros serviços alimentícios foram para o lixo em 2019. Este estudo identificou o desperdício alimentar como um problema significativo à escala global, afetando tanto os países desenvolvidos como os países em desenvolvimento (ONU, 2021).

Um dos principais objetivos da Food and Agriculture Organization for the United Nations (FAO, 2023), é reduzir para metade as perdas globais de alimentos até 2030. A escala dos danos causados por essas perdas é relevante, afetando não só a segurança alimentar, mas também os custos de eliminação dos alimentos desperdiçados e as despesas incorridas com a sua produção

Diante dessa inconstância e com o objetivo de diminuir futuros prejuízos, é prudente que os produtores do agronegócio brasileiro busquem previsões de comportamento de valores. Segundo Puchalskya *et al.*, (2018), os modelos de previsão podem auxiliar nas tomadas de decisões no agronegócio brasileiro tendo em vista o grande número de variáveis presentes neste meio.

A utilização de técnicas de modelagens avançadas está chegando com mais força no agronegócio mundial. Estudos anteriormente realizados, como o apresentado por Kamilaris e Prenafeta-Boldú (2018), utilizaram redes neurais para identificar problemas de falta de vegetação em uma plantação de cana de açúcar. Enquanto Praveen e Sharma (2019), buscaram uma previsão futura dos impactos causados pela variabilidade climática na agricultura utilizando o Modelo Auto Regressivo Integrado de Média Móvel (ARIMA). O ARIMA possui sólida aplicabilidade também nas previsões de preços. Campos e Cordeiro (2006), alcançaram bons resultados com a aplicação do modelo para encontrar as cotações futuras da carne de frango praticadas no varejo do estado de São Paulo.

O estudo de Golmohammadi e Hassini (2019), analisa os movimentos da oferta e demanda aplicados na agricultura. Ele relaciona superproduções ao baixo risco de prejuízos no momento das tomadas de decisões de plantio. Além da análise das quantidades de áreas plantadas de culturas rentáveis nas últimas janelas de produção é plausível aos produtores, possuir o melhor entendimento das condições climáticas da região para a seleção das culturas e oportunidades de ganhos produtivos (Lucena *et al.*, 2012).

Segundo Ruby-Figueroa *et al.*, (2017), o ARIMA é um modelo exploratório adaptado da própria estrutura dos dados, que por meio de funções, pode-se prever os próximos valores da série. Variações aleatórias, tendências, padrões cíclicos são características que o método busca encontrar na série temporal para produzir previsões com certo grau de precisão.

Contribuindo com os modelos de previsão é também utilizado para a resolução de problemas complexos ou abstratos, as Redes Neurais Artificiais (RNA's). Estes modelos matemáticos trabalham similarmente como as redes neurais biológicas, que por meio de uma setorização recebem variáveis de entradas, processam treinamentos, e retornam informações relacionadas aos dados (Cardoso; Cruz, 2016).

O objetivo desse trabalho é realizar uma previsão de valores pagos a produtores da hortaliça Cenoura, na cidade Gaúcha de Caxias do Sul. Utilizando os métodos ARIMA e RNA sobre os dados histórico de preços. Como também verificar sua relação com os índices de precipitação da região. Auxiliando assim, na tomada de decisão de plantio da cultura.

2 FUNDAMENTAÇÃO TEÓRICA

A fundamentação teórica desse artigo está baseada em três tópicos principais: Alimentos, ARIMA e RNA.

2.1 Alimentos

2.1.1 Produção

Durante as duas primeiras décadas do século XXI, se dissipou pelos estudiosos as teorias relativas à superação do estágio agrícola para o melhor desenvolvimento econômico do Brasil (Milani, 2018). Porém, segundo Sznitowski (2017), a agricultura foi determinante para que o país sustentasse os níveis de crescimento no mesmo período. Relacionando tal feito as propícias condições climáticas e geográficas que juntamente com o desenvolvimento do conhecimento e tecnologia proporcionaram o aumento exponencial da produção de alimentos brasileira.

Segundo o Ministério da Agricultura Pecuária e Abastecimento (MAPA, 2020), se projeta um crescimento de 26,7% na produção de grãos em solo brasileiro até 2030. Enquanto que o aumento das áreas cultivadas para essas culturas será de apenas 16,1%, destacando assim o desenvolvimento tecnológico para a produtividade no campo. O órgão público também relaciona as altas demandas do mercado mundial de grãos e carnes com o aumento das lucratividades por meio da elevação dos preços comercializados.

Ao mesmo tempo que essas projeções de plantio e preços apontam para um cenário de constante alta, mesmo durante a pandemia de COVID-19, algumas atividades do agronegócio foram afetadas no Brasil. Hortaliças, frutas e leite foram afetados diretamente, pois as medidas de emergências adotadas pelas autoridades decretam o fechamento de bares, restaurantes e hotéis (Fracalossi, 2020, p.41). Tais alimentos com incapacidade de armazenamento por longos períodos e baixas parcelas de exportação ficam reféns do consumo interno e mais suscetíveis as quedas de valor de mercado (Schabarum; Triches, 2019).

Um dos fatores importantes para o agronegócio brasileiro são os recursos hídricos.

Segundo Singh *et al.*, (2022), a demanda crescente de alimentos e o rápido desenvolvimento econômico, em todo o mundo, conduziram à sobre-exploração dos limitados recursos de água doce. A escassez de recursos de água doce foi agravada pela alteração das condições climáticas e pela contaminação das massas de água doce. Consequentemente, a agricultura emergiu como o principal setor em termos de pegada hídrica, ultrapassando a utilização doméstica e industrial.

A FAO e o Conselho Mundial da Água (CMA, 2023), alertaram, no seu mais recente relatório publicado em 2023, embora haja água suficiente para produzir os alimentos necessários para alimentar a população mundial, que deverá ultrapassar os nove mil milhões de pessoas até 2050, o consumo excessivo, a degradação e os impactos das alterações climáticas reduzirão a disponibilidade de água em muitas regiões, especialmente nos países em desenvolvimento (FAO, 2023).

O relatório, intitulado "Towards a water and food secure future", sublinha a necessidade de políticas governamentais e investimentos dos sectores público e privado para garantir que a produção agrícola, pecuária e piscatória seja sustentável, salvaguardando simultaneamente os recursos hídricos. De acordo com o relatório, estas ações são cruciais para reduzir a pobreza, aumentar os rendimentos e garantir a segurança alimentar das populações das zonas rurais e urbanas (FAO, 2023).

Durante o 7º Fórum Mundial da Água, realizado em Daegu e Gyeongbuk, na Coreia do Sul em 2015, Benedito Braga, Presidente do Conselho Mundial da Água, apresentou o relatório e sublinhou a interdependência da segurança alimentar e da água. Acrescentou que o volume, a qualidade e o acesso à água suficientes para

garantir a segurança alimentar em 2050 e nos anos seguintes poderiam ser alcançados através de abordagens locais e de investimentos adequados efetuados pelos líderes mundiais (WWC, 2015).

De acordo com Montoya e Finamore (2019), o grande e rápido desenvolvimento do agronegócio brasileiro tem notória relação com as vantagens hídricas. Entre os diversos dados apresentados na pesquisa é importante ressaltar que a produção de alimentos incorpora 70,46% de toda a água utilizada na agricultura enquanto que 29,54% retorna a natureza.

A pesquisa realizada por Vargas, Corso e Vallejos (2021), testou as probabilidades de sucesso na colheita de diferentes culturas na cidade de Caxias do Sul levando em consideração as mudanças de temperatura e precipitações utilizando métodos de apoio a tomada de decisão. O cultivo da cenoura nas estações de inverno, outono e primavera se mostrou a mais adequada entre todas as culturas analisadas. Segundo Paulus *et al.*, (2012), a hortaliça cenoura (*Daucus carota*) tem grande importância econômica para o Brasil. Ela pode ser plantada durante todo o ano desde que a cultivar seja adaptada as condições climáticas do local, gerando assim diversas variedades de sementes para cultivo no inverno como também de verão. Métodos de irrigação em cultivares de cenoura estão relacionados à alta produtividade e qualidade da colheita por meio do suprimento hídrico fornecido pelos agricultores no momento em que as raízes precisam (LIMA JUNIOR *et al.*, 2012).

2.1.2 Comércio

A sistemática de comércio de hortigranjeiros nacional mudou muito desde a criação das centrais de abastecimentos (CEASA) na década de 70. São raros os entrepostos que comercializam apenas a produção agrícola local, pois grande proporção atua como importador, beneficiador e distribuidor de diversos alimentos oriundos de todo o território nacional (Cunha; Belik, 2012). Segundo Perobelli *et al.*, (2017), a ampliação da demanda externa dos produtos do agronegócio estimula outras atividades do mercado interno brasileiro, multiplicando e contribuindo para os resultados macroeconômicos. Não foram encontrados dados atuais sobre as quantidades de cenouras brasileiras exportadas, o que reforça a tese da baixa representatividade da cultura na balança comercial do Brasil.

A cenoura, assim como outros produtos hortícolas, não possui uma metodologia padronizada de formação de preços, devido à sua estrutura de mercado, a qual é sinalizada principalmente, pela oferta e demanda diária do produto (Parisoto *et al.*, 2019). A pesquisa também relaciona os modelos de comportamentos dos produtores às expectativas de aumento de consumo, que consequentemente elevam as chances de boas cotações de vendas como também da comercialização integral da produção.

Segundo Taylor (2006), as cadeias de abastecimento de diversos produtos agrícolas no Reino Unido passaram por diversos estudos e mudanças com o intuito de melhorar a gestão da demanda por alimento no país. Os principais problemas foram atribuídos à falta de operações verticais que encurtariam o caminho entre os produtores e consumidores melhorando também a velocidades das informações oriundas do mercado.

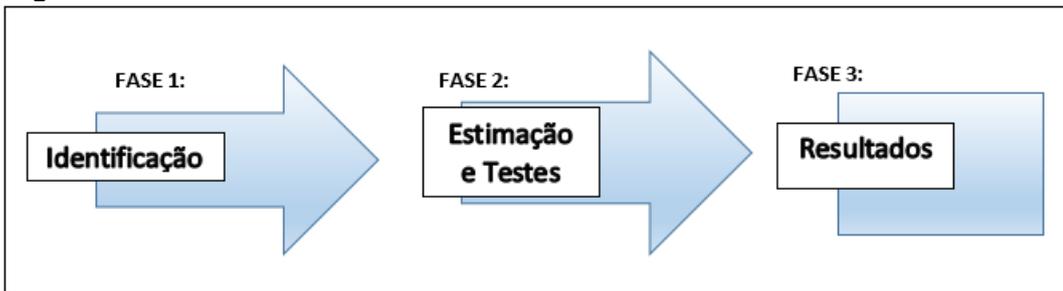
2.2 Arima

A metodologia conhecida como Box-Jenkins ou ARIMA – Autoregressive Integrated Moving Average busca prever um valor futuro de uma variável com base na sua série temporal (Cardoso; Cruz, 2016). A existência de movimentos de tendência nos dados lineares, como também de determinada sazonalidade não são essenciais para a aplicação, porém aumentam a chances de assertividade da técnica sem a necessidade de variações dos dados (Camelo *et al.*, 2017; Nunes, *et al.*, 2023; Dal Bo; Corso, 2022).

Campos e Cordeiro (2006), reafirmam que o ARIMA utiliza da combinação de denominados “filtros”: o componente Auto Regressivo (AR), o filtro de Integração (I) e o componente de médias móveis (MA). O estudo também menciona a generalidade da metodologia Box-Jenkins, que permite trabalhar com qualquer tipo de série, estacionária ou não, tendo como resultado o auto índice de utilização quando se trata de modelos de previsão.

Para se aplicar o modelo ARIMA por meio do método Box-Jenkins é necessário percorrer uma sequência de 3 etapas, como apresentado na Figura 1.

Figura 1 - Fases do Modelo ARIMA



Fonte: adaptado de (CAMPOS; CORDEIRO, 2006).

▪ Fase 1: Nesta fase é necessário analisar e preparar os dados para se adaptarem ao método. Tais medidas serão realizadas com o intuito de estabilizar a variância encontrada inicialmente, como também a realização da diferenciação em busca da estacionariedade (Silva *et al.*, 2019).

▪ Fase 2: Definir os parâmetros p , d e q , que são representados respectivamente por: parâmetro dos números de defasagem (ordem da regressão que a variável futura tem com os valores defasados); parâmetro da ordem de diferenciação (número de diferenças não sazonais necessárias para a estacionariedade) e parâmetro da ordem do modelo de média móvel (número de erros de previsão defasados na equação de previsão) (Lima; Corso, 2020).

▪ Fase 3: Aplicar os dados levantados na equação para resultar em um valor de previsão.

Para a utilização dos dados, aplica-se a Equação 1:

$$y_t = c + \alpha_1 y_{t-1} + \alpha_2 y_{t-2} + \dots + \alpha_p y_{t-p} + \epsilon_t - \theta_1 \epsilon_{t-1} - \theta_2 \epsilon_{t-2} - \dots - \theta_q \epsilon_{t-q} + \epsilon_t \quad (1)$$

Onde:

- y_t = variável que será encontrada no tempo t ;
- c = constante;
- α_1 a α_p = coeficientes de regressão automática;
- θ_1 a θ_q = coeficientes da média móvel;
- ϵ_t = resíduos de erro no tempo t .

2.3 Rede Neural Artificial

Segundo Thiele e Adami (2016), as Redes Neurais Artificiais (RNA) são a técnica mais usada na previsão de séries temporais financeiras, relacionando tal fato ao seu poder de generalização. “Uma RNA é um modelo matemático inspirado na

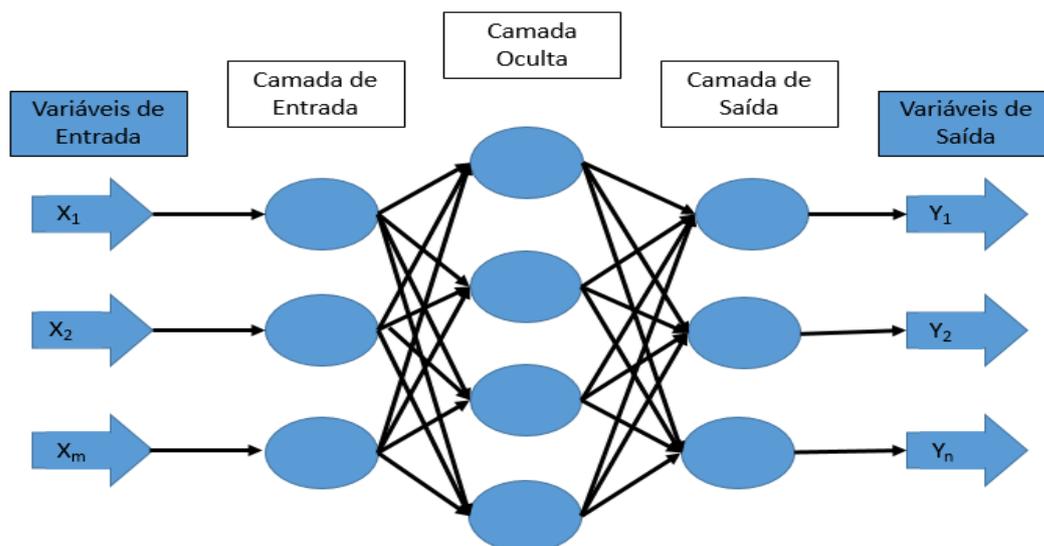
neurobiologia, cujo objetivo é representar a cognição humana ou o neurônio biológico de forma generalizada” (Oliveira *et al.*, 2015, p. 82). Pode-se considerar também que sua principal propriedade é sua capacidade de aprendizado por meio da modificação dos parâmetros, vale ressaltar que ela acontece de forma iterativa.

As RNAs são capazes de modelar sistemas não lineares, os quais geralmente possuem relação com variáveis desconhecidas ou muito complexas. É o caso do estudo realizado por Alves *et al.*, (2018), que buscou estimativas de produtividade da soja relacionando diferentes técnicas de produção agrícola por meio de uma rede neural artificial.

A metodologia para aplicação de uma RNA segue as etapas clássicas de modelagem matemática: definição do problema; aquisição, limpeza e preparação dos dados; modelagem; treino/testes; validação. Primeiramente é necessário identificar o que o método, no caso a RNA, deverá prever. Na sequência a aquisição dos dados para a previsão será tão importante quanto uma limpeza e preparação dos mesmos para que se adaptem ao modelo. Quando se trata das RNA's a modelagem dos parâmetros do método está relacionada diretamente com os resultados das previsões, assim é recomendado que uma boa fase de treinamento da rede seja desenvolvida para definir os parâmetros que resultarão a maior acuracidade no específico caso. Por fim, com a RNA configurada será possível realizar a validação do método para o período desejado (Lima; Corso, 2020).

Uma RNA possui estrutura com três partes principais: entrada (m variáveis), oculta e saída (n variáveis). A primeira é responsável pela recepção dos estímulos de entrada, a segunda tem a finalidade de absorver o comportamento dos dados de entrada e modificar sua estrutura interna para processar o complexo comportamento dos dados, e a terceira basicamente entrega os sinais de saída (Souza; Ribeiro; Silva, 2021). Conforme apresentado na Figura 2.

Figura 2 - Exemplo de estrutura de RNA



Fonte: Adaptado de (Cardoso; Cruz, 2016).

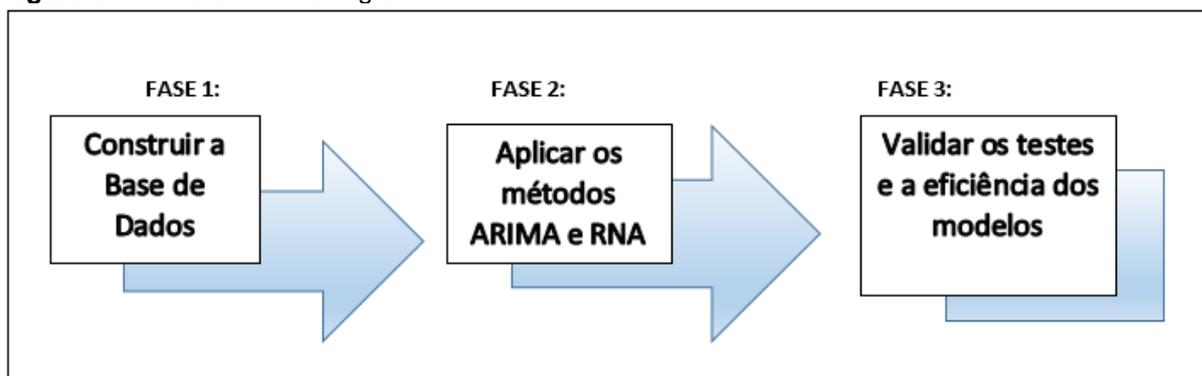
3 MATERIAS E MÉTODO

Por se tratar de uma cultura sobre influência do livre mercado, a cenoura sofre com a volatilidade das cotações ao longo do ano como também com a falta de um padrão de formação dos preços, tais fatores dificultam o planejamento do cultivo por parte dos produtores (Parisoto *et al.*, 2019).

O presente trabalho, por meio de sua metodologia, coletou valores mensais praticados na compra da chamada “cenoura suja” (cotação paga aos produtores) como também dos dados referentes a precipitação total mensal, na região produtora de Caxias do Sul.

Com o objetivo de prever o preço futuro da cenoura para auxiliar os produtores na tomada de decisões de plantio, foram aplicados os modelos ARIMA e RNA. Posteriormente é verificado suas eficiências com a intenção da validação dos métodos para a previsão de preços de alimento. As fases do trabalho são representadas pela Figura 3.

Figura 3 - Fases da metodologia



Fonte: Autor (2020).

3.1 Construção Da Base De Dados

3.1.1 Coleta Dos Dados

No presente trabalho foram utilizados dois bancos de coleta de dados. O primeiro é desenvolvido pelo Centro de Estudos Avançados em Economia Aplicada (CEPEA) e define os preços praticados na comercialização da cenoura nos principais centros produtores da cultura. Com a busca realizada no site hfbrasil.org.br considerando o período de janeiro de 2016 a agosto de 2021 com variação mensal da cotação da caixa de 29 kg na cidade de Caxias do Sul/RS. O segundo é desenvolvido pelo Instituto Nacional de Meteorologia (INMET) e traz a precipitação total em diversos locais pelo Brasil. Com solicitação de dados pelo site portal.inmet.gov.br considerando também o período de janeiro de 2016 a agosto de 2021 dos volumes das chuvas na cidade de Caxias do Sul/RS seguindo também a variação mensal.

3.1.2 Avaliação Dos Dados

Após a coleta de dados, os mesmos foram submetidos a uma verificação de correlação entre suas variações no tempo. Ou seja, foi verificado se a variação dos preços na comercialização da cenoura sofre alguma dependência dos volumes das chuvas da região.

Para a realização da verificação se adotou o método de correlações de Pearson que, Oliveira e Alves (2017), mede a associação de conjuntos de valores de diferentes autores. A correlação tende a resultados que variam entre -1 e 1, quanto mais próximo os valores do resultado zero entende-se que a associação é baixa ou

não existe, enquanto que mais próximos dos algarismos -1 e 1 a associação entre as variáveis tende a ser mais forte.

A correlação de Pearson (r) é representada pela Equação 2

$$r = \frac{\sum x_i \cdot y_i - \frac{\sum x_i \cdot \sum y_i}{n}}{\sqrt{\left(\sum x_i^2 - \frac{(\sum x_i)^2}{n}\right) \cdot \left(\sum y_i^2 - \frac{(\sum y_i)^2}{n}\right)}} \quad (2)$$

Onde:

- x_i = variável 1;
- y_i = variável 2;
- n = número de amostras

O método de Spearman busca relações entre processos estocásticos, porém esse é focado em conexões monotônicas, ou seja, variações dos dados em um mesmo sentido por diversas vezes consecutivas (Wang *et al.*, 2015). Este método também foi utilizado na pesquisa e pode ser representado pela Equação 3.

$$\rho = 1 - \frac{6 \sum_{i=1}^n [R_i - i]^2}{n(n^2 - 1)} \quad (3)$$

Onde:

- R_i = posição da i -ésima amostra de tamanho n ;
- n = ordem cronológica de $x_i y_i$;

Tal equação segue o mesmo padrão de resultados entre -1 e 1 aos quais delimitam o método de Pearson e sua escala de tendências de correlação.

3.2 Aplicação Dos Métodos Arima E Rna

3.2.1 Arima

Para a aplicação da metodologia ARIMA foram desenvolvidas as etapas básicas teóricas para a aplicação: identificação, estimação e teste, e resultados. Com o objetivo de encontrar a minimização de erro e a melhor configuração dos dados utilizou-se o software IBM SPSS® que retorna os três parâmetros: p (número de defasagem), d (ordem de diferenciação) e q (ordem do modelo de média móvel).

3.2.2 RNA

Para aplicação das RNA foram adotados como dado de entrada o valor comercializado da caixa de cenoura. A realização do fracionamento do banco de dados foi necessária para a utilização no treinamento da rede (90%) e o restante para a validação do método (10%).

Devido a necessidade de um algoritmo de treinamento, o modelo de Levenberg-Marquardt auxiliou na utilização das RNA. Esse algoritmo realiza uma sequência de simulações de previsões variando as configurações da rede como a quantidade de neurônios e o delay utilizado. Ao final uma dessas configurações teve maior adaptação a série temporal e acuracidade para as previsões. O algoritmo da teoria de Levenberg-Marquardt, de acordo com De Lima e Corso (2020), é representada na Equação 4.

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^t e \quad (4)$$

Onde:

- J = matriz Jacobiana que recebe as primeiras derivadas dos erros;
- μ = taxa de Aprendizagem;
- x = conjunto das variáveis que minimizam o valor da função;
- e = erro de treinamento;
- I = matriz identidade.

3.3 Validação E Teste De Eficiência Dos Modelos

Após a aplicação do ARIMA e RNA se tornou necessário analisar e validar a acuracidade de cada método. Para realizar essa demanda foram adicionados na metodologia os conceitos de Erro médio absoluto (Mean Absolute Error (MAE)) e a Erro Percentual Médio Absoluto (Mean Absolute Percentage Error (MAPE)) que são representadas respectivamente pelas Equações 5 e 6 (YASEEN *et al.*, 2017).

$$MAE = \frac{1}{N} \sum_{i=1}^N |Q_{i,o} - Q_{i,f}| \quad (5)$$

Onde:

- $|Q_{i,o} - Q_{i,f}|$ = diferença do valor previsto pelo valor real;
- N= número de períodos de avaliação;
- i = séries temporais previstas.

$$MAPE = \frac{100}{N} \sum \left| \frac{r_i - p_i}{p_i} \right| \quad (6)$$

Onde:

- $\left| \frac{r_i - p_i}{p_i} \right|$ = módulo da diferença do valor previsto pelo valor real dividido pelo valor real;
- N= número de períodos de avaliação;
- i = séries temporais previstas.

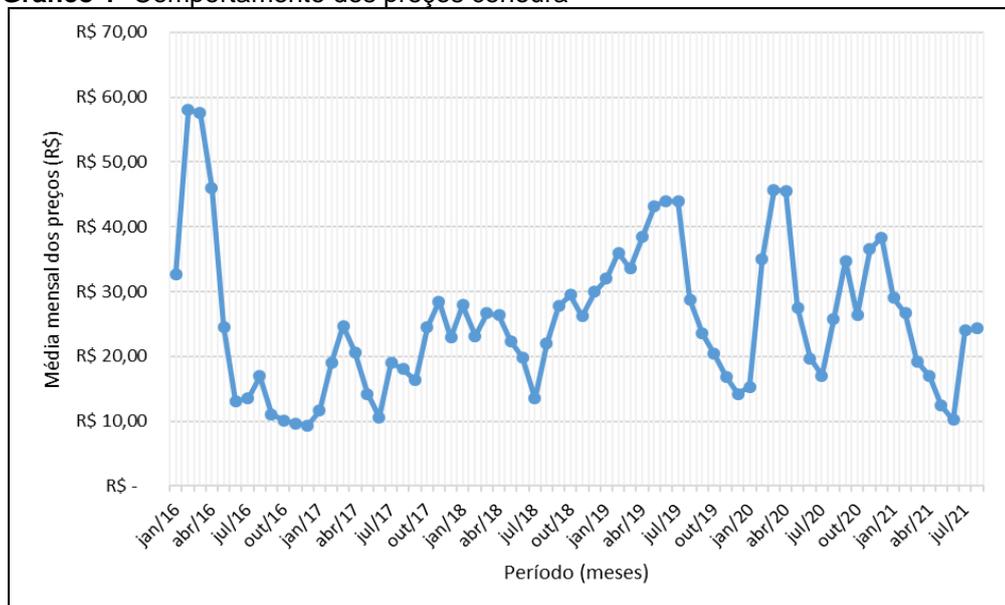
Com a aplicação das equações que representam os erros de cada modelo de previsão foi possível encontrar os métodos e configurações que mais se aproximaram da realidade. Desta forma, foram utilizados para prever as cotações das cenouras do período de janeiro a agosto de 2021 e submetidos a comparação dos erros para definir o de melhor acuracidade.

Caso a acuracidade das previsões desses métodos seja validada os modelos utilizados podem se tornar uma importante ferramenta na tomada de decisão de plantio dos produtores. Enquanto que altas margens de erro nas previsões podem representar que os dados de cotações passadas e climáticos não são os únicos e principais balizadores dos preços futuros de alimentos agrícolas.

4 APRESENTAÇÃO DOS RESULTADOS

Para a aplicação dos métodos foram coletados os dados referentes as médias mensais dos preços pagos aos produtores pela caixa de 29 kg de cenoura em reais no período entre janeiro de 2016 a agosto de 2021. Foi realizada uma seleção dos valores com o objetivo de remover duplicatas nos meses que possuem cotações para mercadorias de plantio de verão e inverno, sendo preservado a lógica de um único dado de preço para cada mês do ano. O comportamento da variação do preço é representado no gráfico a seguir:

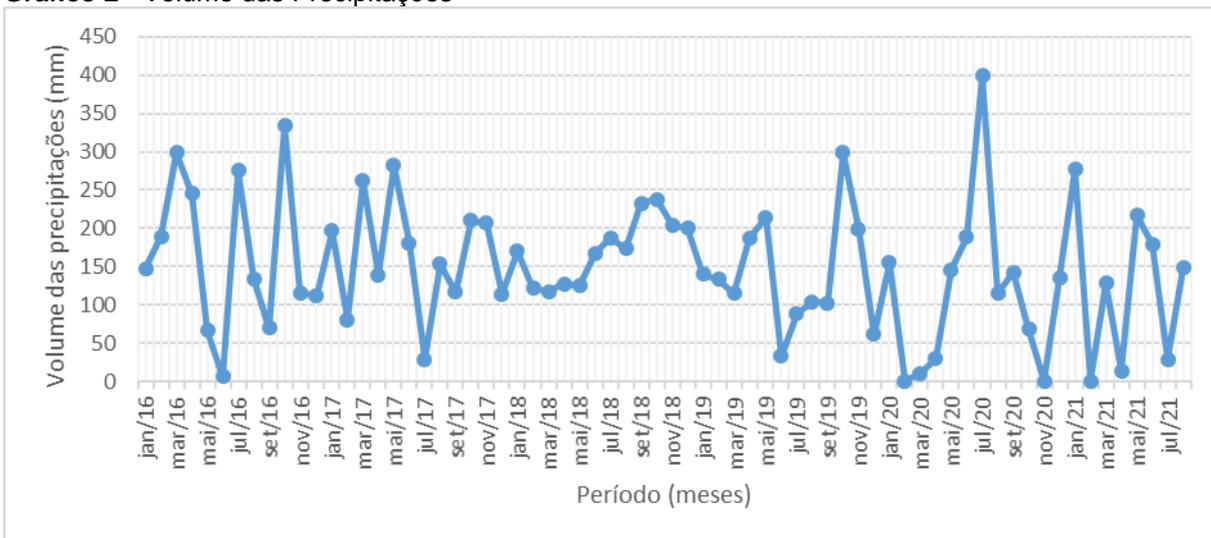
Gráfico 1- Comportamento dos preços cenoura



Fonte: Autor (2023).

Para mensurar a importância das chuvas na variação dos preços se tornou necessário coletar também o volume total mensal das precipitações em mm na cidade de Caxias do Sul/RS no período de janeiro de 2016 a agosto de 2021. O comportamento desses dados é representado no gráfico a seguir:

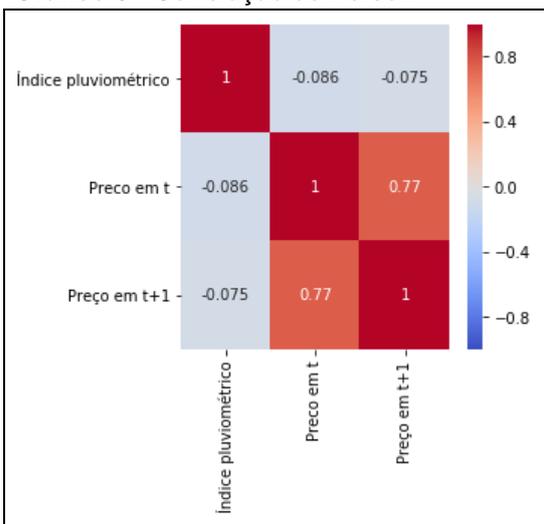
Gráfico 2 - Volume das Precipitações



Fonte: Autor (2023).

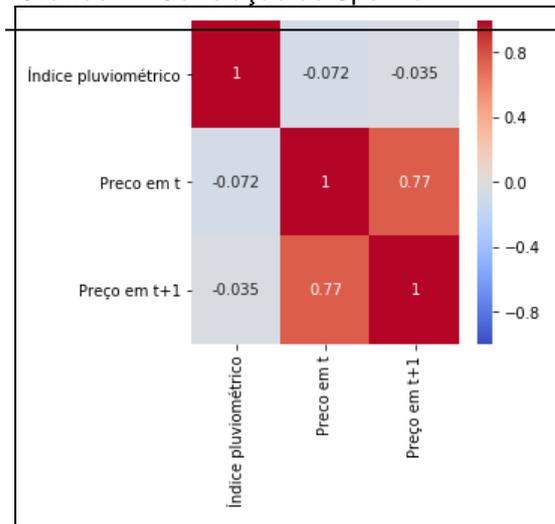
Com a intenção de verificar uma possível correlação entre os dados coletados, foram aplicados os coeficientes de correlação de Pearson e Spearman. Utilizando o script do programa Python ® foi possível criar as duas matrizes que representam o grau de correlação entre o preço da cenoura e o volume das chuvas como também a correlação do preço atual da hortaliça com o período imediatamente anterior.

Gráfico 3 - Correlação de Person



Fonte: Autor (2023).

Gráfico 4 - Correlação de Sperman



Fonte: Autor (2023).

Analisando o comportamento dos gráficos 3 e 4 é possível avaliar que a variação no preço da cenoura tem fraca relação com a variação dos índices

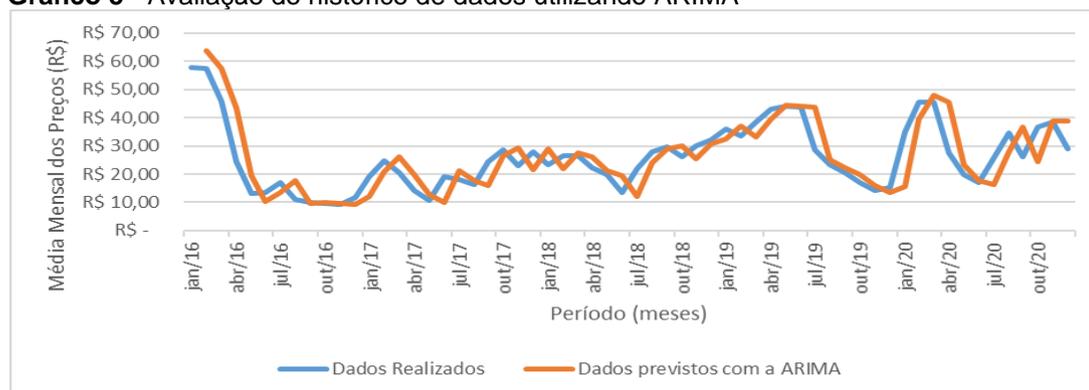
pluviométricos pelos índices de Person e Sperman estarem próximos a 0. Logo, na maioria dos meses analisados não houve uma constância de comportamento nem em modo quanto em grau da variação dos preços da hortaliça em relação ao excesso ou a falta das chuvas. Isso não invalida a tese da importância das precipitações para produção agrícola, mas sim que não é apenas essa a variável que vai fundamentar os preços o ano todo.

Outra observação possível, é que a variação do preço futuro da mercadoria possui certa relação com o preço atual pelo fato dos índices de Person e Sperman resultarem o valor de 0,77, próximo a 1. Tal observação pode ser corroborada pelo gráfico 1, quando é comum encontrar períodos de sequencias de altas ou baixas nos preços, durante alguns meses do ano.

Para realizar o treinamento dos métodos matemáticos foram utilizados os dados referentes aos anos de 2016 a 2020, permitindo assim que alterações em suas programações resultassem previsões mais assertivas.

Utilizando o software IBM SPSS ® foi aplicado o modelo ARIMA. Os valores estimados que obtiveram a melhor configuração nos parâmetros p,d e f foram respectivamente (2,0,0). Tal configuração indica uma ordem 2 para o nível de defasagem (p) e grau 0 para diferenciação (d) e média móvel (f), o que referenciaria uma configuração AR (2). Tal configuração resultou os valores mostrados no Gráfico 5.

Gráfico 5 - Avaliação do histórico de dados utilizando ARIMA

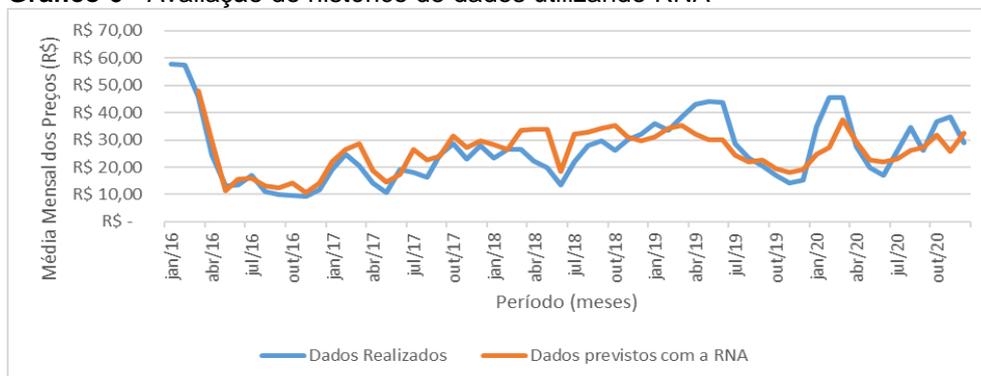


Fonte: Autor (2023).

Para a aplicação do modelo de RNA, foi utilizado o algoritmo de aprendizagem Levenberg Marquardt. As redes neurais foram treinadas e testadas com uma variação de neurônios de 10 a 100, com passo 10, como também com a mudança do delay utilizado de 1 a 10. Com todas as combinações geradas a que Revista Produção Online. Florianópolis, SC, v. 23, n. 1, e-4869, 2023.

resultou um menor MAE de previsão foi a configuração com 30 neurônios e delay igual a 2. Ela previu os dados representadas no gráfico 6.

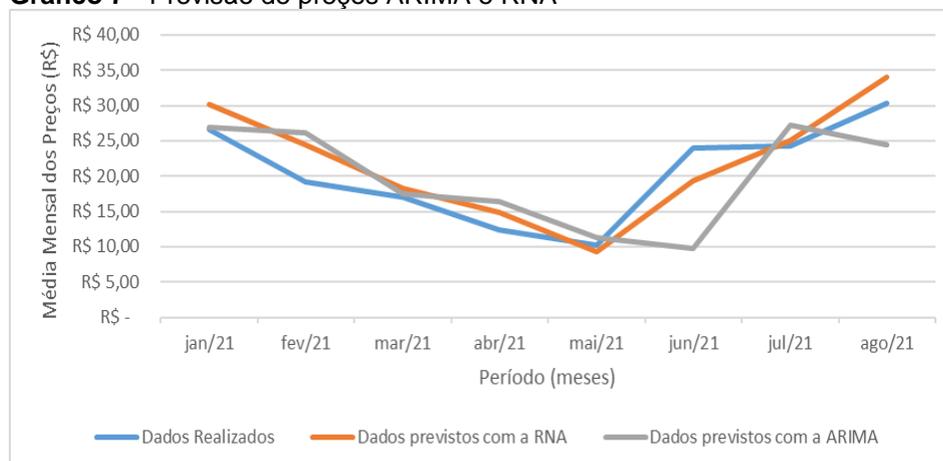
Gráfico 6 - Avaliação do histórico de dados utilizando RNA



Fonte: Autor (2023).

Com as melhores configurações encontradas para os métodos foi possível mensurar a acuracidade das previsões em relação aos dados de preço referentes ao período de janeiro de 2021 a agosto de 2021. Os resultados são representados no gráfico 7.

Gráfico 7 - Previsão de preços ARIMA e RNA



Fonte: Autor (2023).

Para medir a eficiência dos modelos de previsão foram submetidos os resultados a duas métricas de avaliação (MAE e MAPE). Como pode ser observado na tabela a seguir o modelo por RNA apresentou melhores resultados na comparação com o ARIMA.

Tabela 1 - Erros estatísticos dos modelos de previsão

TESTES	ARIMA	RNA
MAE	4,48	2,81
MAPE	21,75%	13,95%

Fonte: Autor (2023).

5 CONCLUSÃO

Um melhor conhecimento do comportamento de preços das produções agrícolas é uma possibilidade aos produtores rurais de melhorarem seus negócios. A constante movimentação dos preços das commodities agrícolas quanto de hortaliças, frutas e verduras, aliadas a variação nos preços dos insumos necessários para a produção leva aos agricultores assumirem altos riscos financeiros no momento do investimento de plantio. Porém, a tarefa de prever preços futuros no ramo do agronegócio não é tão simples, questões principalmente qualitativas baseadas na experiência de especialistas costumam não ser objetivas e algumas vezes pouco assertivas.

Esse artigo teve como objetivo prever valores futuros pagos a produtores pela cenoura produzida na cidade de Caxias do Sul por dois modelos matemáticos, o ARIMA e as RNA's. Um objetivo secundário era verificar a relação entre o volume das precipitações na região e o preço da hortaliça, para isso foram utilizados os modelos de correlação de Person e Spearman que apontaram baixa dependência entre as cotações e o volume das chuvas, corroborando a tese que demais variáveis possam interferir de forma mais significativa. Outra possibilidade é que o tipo de correlação apresentada pode não necessariamente ser capaz de representar o comportamento de ambas as variáveis.

Os dados históricos das cotações foram coletados e selecionados para posteriormente serem divididos em dois períodos: janeiro de 2016 a dezembro de 2020, para realização da fase de treinamento, janeiro de 2021 a agosto de 2021 para a validação dos modelos matemáticos.

A configuração do ARIMA que resultou no menor erro foi a dos parâmetros (2,0,0). Já na RNA a rede ficou formada por 30 neurônios e delay igual a 2. Embora essas tenham sido as melhores configurações encontrada vale ressaltar que em

demais simulações será necessário a reavaliação dos parâmetros tendo em vista a sensibilidade observada.

Na comparação dos erros MAPE e MAE aos quais os modelos matemáticos foram submetidos a RNA foi a que obteve menor índice. O modelo de inteligência artificial se distanciou em média 13,95 % das cotações reais o que indica ser um valor bem aceitável levando em consideração a variação dos dados.

As limitações do estudo sobre a previsão dos preços dos produtos alimentícios utilizando o método ARIMA e a inteligência artificial podem incluir; a) disponibilidade de dados: a precisão das previsões pode ser limitada pela disponibilidade e qualidade dos dados históricos. Se os dados forem incompletos ou imprecisos, os modelos podem não ser capazes de gerar previsões fiáveis; b) pressupostos do modelo: os modelos ARIMA partem de pressupostos sobre a estacionariedade dos dados e a ausência de tendências e sazonalidade. Estes pressupostos podem não ser válidos para todos os tipos de preços dos alimentos, o que pode afetar a exatidão das previsões; c) aplicabilidade limitada: o estudo pode focar em uma região específica ou num conjunto de preços dos produtos alimentares, o que limita a sua aplicabilidade a outras regiões ou produtos alimentares; d) incerteza: o futuro é inerentemente incerto, e a exatidão de qualquer previsão está sujeita a esta incerteza. Acontecimentos inesperados, como catástrofes naturais, instabilidade política ou pandemias, podem perturbar a oferta e a procura de produtos alimentares, tornando as previsões obsoletas; e) ausência de conhecimentos humanos: apesar a IA possa fazer previsões exatas com base em dados, pode não ter a compreensão contextual e os conhecimentos humanos que podem ter impacto nos preços dos alimentos, tais como alterações nas preferências dos consumidores ou nas políticas governamentais.

Para estudos futuros seria interessante mensurar novas variáveis de entrada para as redes neurais com o intuito de diminuir os erros das previsões e encontrar melhores índices de correlações entre esses dados e as cotações de preços.

REFERÊNCIAS

ALVES, G. R.; TEIXEIRA, I. R.; MELO, F. R.; SOUZA, R. T. G.; SILVA, A. G. Estimating soybean yields with artificial neural networks. *Acta Scientiarum*.

Agronomy, 40. Estimating soybean yields with artificial neural networks. **Acta Scientiarum**. Agronomy, v. 40, p. e35250, 2018. DOI: <https://doi.org/10.4025/actasciagron.v40i1.35250>

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento (MAPA). **Projeções do Agronegócio**: Brasil 2012/2013 a 2022/2023. Ministério da Agricultura, Pecuária e Abastecimento. Assessoria de Gestão Estratégica. Brasília: Mapa/ ACS, 2013. 96 p. Disponível em: <https://www.gov.br/agricultura/pt-br/assuntos/politica-agricola/todas-publicacoes-de-politica-agricola/projecoes-do-agronegocio/projecoes-do-agronegocio-brasil-2012-2013-a-2022-2023.pdf/view>. Acesso em: 27 maio.2023.

CAMELO, H. D. N.; LUCIO, P. S.; LEAL, J. B. V.; DE CARVALHO, P. C. M. Métodos de previsão de séries temporais e modelagem híbrida ambos aplicados em médias mensais de velocidade do vento para regiões do Nordeste do Brasil. **Revista Brasileira de Meteorologia**, v. 32, p. 565-574, 2017. DOI: <https://doi.org/10.1590/0102-7786324005>

CAMPOS, P. A. C.; CLEMENTE, A.; DE CORDEIRO, A. A. L. Aplicação do modelo ARIMA para previsão do preço do frango inteiro resfriado no grande atacado do estado de São Paulo. *In*: CONGRESSO BRASILEIRO DE CUSTOS, 2006, Belo Horizonte, 12., **Anais [...]**. Belo Horizonte: Associação Brasileira de Custos, 2006. p. 1-16.

CARDOSO, C. A. V.; CRUZ, G. L. Forecasting Natural Gas Consumption using ARIMA Models and Artificial Neural Networks. **Ieee Latin America Transactions**, v. 14, n. 5, p. 2233-2238, 2016. Institute of Electrical and Electronics Engineers (IEEE). DOI: <http://dx.doi.org/10.1109/tla.2016.7530418>.

CONFEDERAÇÃO DA AGRICULTURA E PECUÁRIA DO BRASIL. **Boletim do PIB do Agronegócio 2022**. Disponível em: <https://www.cnabrazil.org.br/publicacoes/apos-alcancar-patamar-recorde-em-2021-pib-do-agronegocio-recua-4-22-em-2022>. Acesso em: 25 de abr. 2023.

CONFEDERAÇÃO DA AGRICULTURA E PECUÁRIA DO BRASIL. **Pib do agronegócio alcança participação de 26,6% no Pib brasileiro em 2020**. [S.l]: Cepea, 2021. 18 p.

SILVA, D. R.; DOMINGUEZ, D. S.; AMBROSIO, P. E.; IGLESIAS, S. M. Método híbrido de redes neurais e modelo ARIMA na previsão do custo da cesta básica na cidade de Ilhéus. **Revista Mundi Engenharia, Tecnologia e Gestão**, v. 4, n. 3, 2019.

DAL BO, G.; CORSO, L. L. Aplicação de aprendizado de máquina para aumento de precisão de um sistema automatizado de nutrição de suínos. **Revista Produção Online**, v. 22, n. 1, p. 2428-2451, 2022. DOI: <http://dx.doi.org/10.14488/1676-1901.v22i1.4586>
Disponível em: <https://www.producaoonline.org.br/rpo/article/view/4586>. Acesso em: 13 maio. 2023.

ALMEIDA CUNHA, A. R. A.; BELIK, W. A produção agrícola e a atuação das Centrais de Abastecimento no Brasil. **Segurança Alimentar e Nutricional**, v. 19, n. 1, p. 46-59, 2012.

LIMA, D.; CORSO, L. L. Aplicação de Inteligência Artificial e Modelos Matemáticos para Previsão de Demanda em uma indústria do ramo plástico. **Scientia cum Industria, Caxias do Sul**, v. 8, n. 2, p. 24-29, 2020.

OLIVEIRA, E. F. T.; ALVES, B. H. Cosseno de Salton, Índice de Jaccard e Correlação de Pearson: comparando índices normalizados e absolutos em análise de cocitação de autores. **Em Questão**, v. 23, p. 235, 27 jan. 2017. DOI. <http://dx.doi.org/10.19132/1808-5245230.235-253>

SOUZA, W. M.; RIBEIRO, A. J. A.; DA SILVA, C. A. U. Uma abordagem alternativa para obtenção da classificação de solos da AASHTO usando redes neurais artificiais. **Transportes**, v. 1, n. 1, p. 41-54, abr. 2021. Disponível em: <https://www.revistatransportes.org.br/anpet/article/view/2176/877>. Acesso em: 03 dez. 2021.

FOOD AND AGRICULTURE ORGANIZATIONS OF THE UNITED NATIONS – FAO DATABASE. Disponível em: <https://www.fao.org/documents/card/en/c/eb978434-dac0-4cd0-bcb3-f1f6f01>. Acesso em: 13 maio. 2023.

FOOD AND AGRICULTURE ORGANIZATIONS OF THE UNITED NATIONS – FAO DATABASE. Disponível em: <http://aguasdobrasil.org/downloads/pdf/Revista-Aguas-do-Brasil-12.pdf>. Acesso em: 13 maio. 2023.

FRACALOSSO, M. R. **Covid-19 e medidas legais de distanciamento social:** tipologia de políticas estaduais e análise do período de 13 a 26 de abril de 2020. Nota Técnica nº18, abril de 2020. Instituto de Pesquisa Econômica Aplicada – IPEA. Disponível em: https://portalantigo.ipea.gov.br/agencia/images/stories/PDFs/nota_tecnica/200429_nt_18_covid-19.pdf. Acesso em: 27 maio. 2023.

GOLMOHAMMADI, A.; HASSINI, E. Capacity, pricing and production under supply and demand uncertainties with an application in agriculture. **European Journal Of Operational Research**, v. 275, n. 3, p. 1037-1049, 2019 . DOI: <http://dx.doi.org/10.1016/j.ejor.2018.12.027>

KAMILARIS, A.; PRENAFETA-BOLDÚ, F. X. A review of the use of convolutional neural networks in agriculture. **The Journal Of Agricultural Science**, p. 312-322.

LIMA JUNIOR, J. A.; PEREIRA, G. M.; GEISENHOF, L. O.; SILVA, W. G. D.; VILAS BOAS, R. C., SOUZA, R. J. D. Desempenho de cultivares de cenoura em função da água no solo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 16, p. 514-520, 2012.

LUCENA, J.; SOUZA, B. I.; MOURA, M.; DE OLIVEIRA LIMA, J. Análise da variabilidade da precipitação pluviométrica como subsídio para o planejamento

Revista Produção Online. Florianópolis, SC, v. 23, n. 1, e-4869, 2023.

agrícola em Caicó/RN. **Revista Brasileira de Climatologia**, v. 10, n. 8, p. 1-15, jun. 2012.

LUDOVICO, S. N.; SALGADO, R. M.; BEIJO, L. A.; MIGUEL, E. C.; REZENDE, M. L. Agricultural commodity price prediction via machine learning algorithms. **Sigmae**, v. 11, n. 2, p. 45-69, jan. 2023.

MILANI, C. R. **Solidariedade e Interesse: Motivações e Estratégias Na Cooperação Internacional Para o Desenvolvimento**. 1 ed. Curitiba, PR: Appris, 2018.

MONTOYA, M. A.; FINAMORE, E. B. Os recursos hídricos no agronegócio brasileiro: uma análise insumo-produto do uso, consumo, eficiência e intensidade. **Centro de Pesquisa e Extensão da Feac**, Passo Fundo, v. 1, n. 1, p. 1-22, out. 2019.

OLIVEIRA, A. A.; SIQUEIRA, P. H.; NISGOSKI, S.; MUNIZ, G. B. D.; FERREIRA, J. H. Identificação de madeiras utilizando a espectrometria no infravermelho próximo e redes neurais artificiais. **TEMA**, São Carlos-SP, v. 16, p. 81-95, 2015. DOI: <https://dx.doi.org/10.5540/tema.2015.016.02.0081>

PARISOTO, G. J.; GUIMARÃES, V. D. A. Análise da cadeia da cenoura: um estudo de caso no estado do paraná. *In*: CONGRESSO DA SOCIEDADE BRASILEIRA DE ECONOMIA, ADMINISTRAÇÃO E SOCIOLOGIA RURAL, 57., 2019, Ilhéus. Biodiversidade, Meio Ambiente e Desenvolvimento Sustentável. [S.L.]: Editora Conhecimento Livre, 2020. p. 1-19.

PAULUS, D.; MOURA, C. D. A.; SANTIN, A.; DALHEM, A. R.; NAVA, G. A.; RAMOS, C. E. Produção e aceitabilidade de cenoura sob cultivo orgânico no inverno e no verão. **Horticultura Brasileira**, v. 30, n. 3, p. 446-452, set. 2012. DOI: <http://dx.doi.org/10.1590/s0102-05362012000300015>

PEROBELLI, F. S.; BETARELLI, A. A.; VALE, V. D. A.; CUNHA, R. G. Impactos Econômicos do Aumento das Exportações Brasileiras de Produtos Agrícolas e Agroindustriais para Diferentes Destinos. **Revista de Economia e Sociologia Rural**, v. 55, n. 2, p. 343-366, 2017. DOI: <http://dx.doi.org/10.1590/1234-56781806-94790550208>

PRAVEEN, B.; SHARMA, P. Climate variability and its impacts on agriculture production and future prediction using autoregressive integrated moving average method (ARIMA). **Wiley**, v. 156, n. 3, p. 1-12, 2019.

PUCHALSKY, W.; RIBEIRO, G. T.; DA VEIGA, C. P.; FREIRE, R. Z.; DOS SANTOS COELHO, L. Agribusiness time series forecasting using Wavelet neural networks and metaheuristic optimization: An analysis of the soybean sack price and perishable products demand. **International Journal Of Production Economics**, p. 174-189, 2018. Disponível em: www.elsevier.com/locate/ijpe. Acesso em: 14 abr. 2021.

RUBY-FIGUEROA, R.; SAAVEDRA, J.; BAHAMONDE, N.; CASSANO, A. Permeate flux prediction in the ultrafiltration of fruit juices by ARIMA models. **Journal Of**

Membrane Science, v. 524, p. 108-116, fev. 2017. DOI:
<http://dx.doi.org/10.1016/j.memsci.2016.11.034>

SCHABARUM, J. C.; TRICHES, R. M. Aquisição de Produtos da Agricultura Familiar em Municípios Paranaenses: análise dos produtos comercializados e dos preços praticados. **Revista de Economia e Sociologia Rural**, v. 57, n. 1, p. 49-62.2019. DOI: <http://dx.doi.org/10.1590/1234-56781806-94790570103>

SINGH, V. K.; RAJANNA, G. A.; PARAMESHA, V.; UPADHYAY, P. K. Agricultural Water Footprint and Precision Management. **Sustainable Agriculture Systems and Technologies**, p. 251-266, 2022. DOI: <https://doi.org/10.1002/9781119808565.ch11>

SZNITOWSKI, A. M. Fontes de conhecimento/tecnologia para o agronegócio da soja em Mato Grosso. **Revista UNEMAT de Contabilidade**, v. 6, n. 11, 2017.

TAYLOR, D. H. Demand management in agri-food supply chains. **The International Journal Of Logistics Management**, v. 17, n. 2, p. 163-186, DOI:
<http://dx.doi.org/10.1108/09574090610689943>

THIELE, C. C.; ADAMI, A. G. Previsão de séries temporais financeiras: modelo baseado em redes neurais artificiais. **Revista Brasileira de Computação Aplicada**, v. 8, n. 2, p. 113, 1, 2016. DOI: <http://dx.doi.org/10.5335/rbca.v8i2.5638>

ONU. Disponível em: <https://brasil.un.org/pt-br/114718-onu-17-de-todos-os-alimentos-dispon%C3%ADveis-para-consumo-s%C3%A3o-desperdi%C3%A7ados>. Acesso em: 12 maio. 2023.

VARGAS, V. B.; CORSO, L.; VALLEJOS, R. V. Markov chains to determine the probability of climate change for planting selection in the city of Caxias do Sul. **Ciência Rural**, v. 52, n. 4, p. 1-7, 2021.

WANG, W.; CHEN, Y.; BECKER, S.; LIU, B. Linear trend detection in serially dependent hydrometeorological data based on a variance correction Spearman rho method. **Water**, v. 7, n. 12, p. 7045-7065, 2015 DOI:
<http://dx.doi.org/10.3390/w7126673>

WORLD WATER COUNCIL. Disponível em:
<https://www.worldwatercouncil.org/en/daegu-gyeongbuk-2015>. Acesso em: 12 maio. 2023.

Leonardo Scodro

Sócio proprietário de uma empresa comercial agrícola do ramo de leguminosas. Seu trabalho além da gestão financeira baseia-se na análise do mercado por métodos estatísticos, buscando auxiliar a tomada de decisões comerciais e produtivas. Graduado em Engenharia de Produção pela Universidade de Caxias do Sul, tem como pesquisa operacional a área de estudo pela qual mais tem interesse.

Leandro Luís Corso

Pós-doutorado na Naval Postgraduate School (EUA). Doutorado e Mestrado pela (UFRGS), Graduação em Engenharia Mecânica pela Universidade de Caxias do Sul (UCS). Professor / Pesquisador da UCS. Consultor em empresas multinacionais nas áreas de Otimização e Inteligência Artificial.



Artigo recebido em: 19/03/2023 e aceito para publicação em: 31/05/2023

DOI: <https://doi.org/10.14488/1676-1901.v23i1.4869>