

**PREVISÃO DE COMMODITY LARANJA UTILIZANDO MÉTODOS DE
REGRESSÃO E CIÊNCIA DE DADOS**
***ORANGE COMMODITY FORECASTING USING REGRESSION METHODS AND
DATA SCIENCE***

Alexander Ferreira – alexander.ferreira@fatec.sp.gov.br
Faculdade de Tecnologia de Bebedouro “Jorge Caram Sabbag” – Bebedouro – SP – Brasil

Renan Guilherme Nespolo – renan.nespolo01@fatec.sp.gov.br
Faculdade de Tecnologia de Bebedouro “Jorge Caram Sabbag” – Bebedouro – SP – Brasil

DOI: 10.31510/inf.v22i2.2372

Data de submissão: 26/09/2025

Data do aceite: 03/12/2025

Data da publicação: 20/12/2025

RESUMO

O mercado de commodities é crucial para a economia global, impactando setores como agricultura, energia e metais. Sua volatilidade decorre de fatores externos como instabilidades geopolíticas, clima e variações de oferta e demanda, exigindo análise constante de riscos futuros. Este estudo avalia duas técnicas de regressão *Ridge* e LASSO aplicadas à previsão de preços da laranja, considerando o uso de expansão polinomial e a influência da janela temporal de treino, com validação cruzada (*k-Fold*) e métricas como MSE e MAE. Os resultados mostraram maior robustez do *Ridge* diante da multicolinearidade, enquanto o LASSO foi mais sensível, mas beneficiado pela calibragem via validação. A escolha adequada da técnica e do pré-processamento melhora a capacidade de generalização dos modelos e apoia decisões mais seguras. O estudo reforça a importância de integrar métodos estatísticos e tecnologias emergentes na gestão de riscos em mercados voláteis.

Palavras-chave: Agronegócio. Mercado de Commodities. Riscos Futuros. Volatilidade de Preços. Mitigação de Riscos.

ABSTRACT

The commodity market is crucial for the global economy, impacting sectors such as agriculture, energy, and metals. Its volatility stems from external factors like geopolitical instability, climate, and supply-demand variations, requiring constant risk assessment. This study evaluates two regression techniques Ridge and LASSO applied to orange price forecasting, considering polynomial expansion and the influence of training window size, with cross-validation (K-Fold) and metrics such as MSE and MAE. Results showed Ridge to be more robust against multicollinearity, while LASSO was more sensitive but benefited from calibration via validation. The appropriate choice of technique and preprocessing improves model generalization and

supports safer decisions. The study highlights the importance of integrating statistical methods and emerging technologies in risk management within volatile markets.

. Keywords: *Agribusiness. Commodity Market. Future Risks. Price Volatility. Risk Mitigation.*

1 INTRODUÇÃO

O mercado de commodities é vital para a economia global, impactando setores como agricultura, energia e metais. A alta volatilidade dos preços, causada por fatores geopolíticos, mudanças climáticas e instabilidades econômicas, representa desafios significativos para investidores, empresas e governos (Food and Agriculture Organization of the United Nations, 2025). Segundo Geman (Geman, 2005), a precificação de commodities exige modelos que considerem não apenas a dinâmica de oferta e demanda, mas também os riscos sistêmicos associados à especulação e à interdependência entre mercados. Hull (Hull, 2012) complementa ao afirmar que a gestão de riscos financeiros em instituições depende da capacidade de antecipar movimentos extremos e aplicar estratégias quantitativas robustas.

Analisando os principais fatores de risco que afetam o mercado de commodities, focando na volatilidade dos preços, fatores geopolíticos e mudanças climáticas, a mitigação desses riscos é possível elaborar ferramentas e estratégias e propor abordagens por meio de uma leitura dos números de uma base histórica atualizada, a qual pode-se criar uma análise de risco futuro (Hull, 2012).

Este trabalho realizou uma análise de risco futuro desse mercado, investigando a influência desses fatores na oferta e demanda global. Além disso, explora ferramentas e estratégias de mitigação de riscos, com ênfase em tecnologias emergentes e políticas econômicas. O estudo buscou identificar soluções e diferentes estratégias para ajudem instituições, empresas e governos a tomar decisões embasadas em dados, aumentando a resiliência do setor frente às incertezas futuras. O estudo também buscou contribuir para o debate acadêmico, fornecendo uma análise prática de como o modelo de previsão pode ser utilizado para mitigar riscos no mercado de futuro de agro commodities (Embrapa, 2025). Deste modo, os objetivos do presente estudo são:

- Analisar duas técnicas de regressão, de forma temporal, utilizando duas variáveis: preço de cotação do dólar, e preço de cotação da commodity de laranja.
- Analisar a influência do pré-processamento expansão polinomial no conjunto de dados.

- Propor um modelo de inferência com janela temporal reduzida para validação do método.

O presente estudo está segmentado em: 1 Introdução; 2 Fundamentação Teórica; 3 Materiais e Métodos; 4 Resultados e Discussões; 5 Conclusões e; Referências.

2 FUNDAMENTAÇÃO TEÓRICA

A fundamentação teórica deste estudo está organizada em duas partes principais: a primeira, Agricultura e Riscos Financeiros com Base em Commodities, Seção 2.1, abordando a dinâmica do agronegócio e sua exposição a fatores externos que afetam diretamente a estabilidade dos preços e o planejamento financeiro; a segunda, Análises de dados, regressão, avaliação e pré-processamento (Seção 2.2), explorou o uso de métodos estatísticos e computacionais no tratamento e na previsão de séries temporais, recursos essenciais para interpretação de padrões históricos e antecipar cenários futuros.

Nesse contexto, foram discutidos tópicos como pré-processamento, expansão polinomial, regressão LASSO, regressão *Ridge*, métricas de avaliação e validação cruzada *k-Fold*, evidenciando sua relevância para a construção de modelos preditivos mais robustos e adequados a ambientes voláteis.

2.1 Agricultura e riscos Financeiros Com base em Commodities

A exposição às flutuações nos preços internacionais das commodities é um fator crucial para o planejamento financeiro dos produtores, influenciando desde as decisões de investimento até as estratégias de comercialização (Fabozzi; Drake, 2009).

Além da volatilidade dos preços, os produtores agrícolas enfrentam riscos financeiros decorrentes de variáveis macroeconômicas, como as taxas de câmbio e as políticas governamentais. Geman (Geman, 2005) destaca que as commodities agrícolas são fortemente influenciadas pelas variações cambiais, especialmente em países exportadores como o Brasil, onde a desvalorização da moeda local pode, ao mesmo tempo, elevar a competitividade das exportações e aumentar os custos dos insumos importados. Essa dualidade cria um ambiente de incerteza que exige mecanismos de proteção financeira e estratégias de hedge para mitigar os impactos adversos.

Outro elemento relevante é a incerteza climática, que afeta diretamente a oferta de commodities agrícolas. Eventos climáticos extremos, como secas, geadas e enchentes, podem

reduzir a produção e pressionar os preços, ampliando a volatilidade nos mercados. De acordo com Roncoroni *et al.* (Roncoroni; Fusai; Cummins, 2015), essas oscilações, além de impactarem a renda agrícola, afetam toda a cadeia de suprimentos, incluindo transportadoras, indústrias de processamento e exportadores. Nesse sentido, a compreensão dos riscos climáticos é fundamental para o gerenciamento financeiro eficiente na agricultura.

2.2 Análises de dados, regressão, avaliação e pré-processamento

Com o avanço das tecnologias de ciência de dados, especialmente o uso de algoritmos de aprendizado de máquina, tornou-se possível lidar com volumes massivos de informações e realizar análises mais robustas. Métodos de regressão regularizada, como *Ridge* e LASSO, têm se mostrado eficazes em ambientes com alta dimensionalidade e multicolinearidade, onde variáveis explicativas estão fortemente correlacionadas entre si (Hastie, 2009). Essas técnicas aplicam penalizações aos coeficientes de regressão para reduzir o risco sobre ajuste e melhorar a capacidade preditiva dos modelos.

A regressão *Ridge* é uma técnica de regressão linear que adiciona um termo de penalização à função de custo tradicional, com o objetivo de reduzir o sobre ajuste (*overfitting*) e lidar com problemas de multicolinearidade entre as variáveis explicativas. Introduzida por Hoerl e Kennard (Hoerl; Kennard, 1981), essa abordagem é classificada como uma técnica de regressão regularizada, pois penaliza grandes valores dos coeficientes, restringindo-os a valores menores e mais estáveis. A função de custo da regressão *Ridge* é definida pela equação 1:

$$J(\beta) = \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \lambda \|\beta\|_2^2 \quad (1)$$

na qual: y_i é o valor observado, \hat{y}_i é o valor previsto, λ é o parâmetro de regularização que controla a intensidade da penalização, $\|\beta\|_2^2$ é a norma L2 dos coeficientes β .

A regressão LASSO (*Least Absolute Shrinkage and Selection Operator*) é uma técnica de regressão linear que incorpora um termo de penalização baseado na soma dos valores absolutos dos coeficientes. Proposta por Tibshirani (Tibshirani, 1996), essa abordagem visa solucionar problemas de superajuste (*overfitting*) e seleção de variáveis, sendo particularmente útil quando se trabalha com *Datasets* de alta dimensionalidade ou com variáveis altamente

correlacionadas. Matematicamente, a função de custo do modelo de regressão LASSO é definida pela equação 2:

$$J(\beta) = \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \lambda \|\beta\|_1 \quad (2)$$

na qual: y_i é o valor observado, \hat{y}_i é o valor previsto, λ é o parâmetro de regularização que controla a intensidade da penalização, $\|\beta\|_1$ é a norma L1 dos coeficientes, ou seja, a soma dos valores absolutos dos coeficientes de β (Hoerl; Kennard, 1981).

3 MATERIAIS E MÉTODOS

Neste estudo, as análises foram conduzidas por meio da linguagem de programação Python, utilizando a biblioteca *scikit-learn* para desenvolver os modelos de regressão LASSO e *Ridge*. O ambiente de desenvolvimento adotado foi o *Visual Studio Code*, amplamente reconhecido entre profissionais da área por sua versatilidade, compatibilidade com extensões e integração eficiente com ferramentas voltadas à ciência de dados. A performance dos modelos foi avaliada com base nas métricas *Mean Squared Error* (MSE) e *Mean Absolute Error* (MAE), que possibilitam mensurar o grau de precisão das estimativas geradas pelos algoritmos de regressão.

A etapa de pré-processamento dos dados foi realizada com a biblioteca *preprocessing* do *scikit-learn*, incluindo a transformação dos dados por meio da técnica *Polynomial Features*. Segundo Hastie (Hastie, 2009), "os modelos de regressão polinomial estendem os modelos lineares ao considerar transformações polinomiais dos preditores.

Os modelos de regressão LASSO e *Ridge* foram treinados e testados utilizando diferentes configurações de pré-processamento. Inicialmente, os modelos foram ajustados sem a aplicação de *Polynomial Features*, permitindo uma análise comparativa entre a regressão linear tradicional e a versão polinomial. Em seguida, os mesmos modelos foram treinados com a transformação polinomial, verificando o impacto da inclusão de características não lineares na precisão das previsões. A validação cruzada foi aplicada em ambas as abordagens, utilizando *Forward Chaining* e *k-Fold Cross-Validation*, garantindo uma avaliação estatisticamente significativa dos resultados (Hastie, 2009).

Por fim, os resultados obtidos foram analisados e comparados, verificando a influência do pré-processamento e da escolha do modelo na precisão das previsões. A utilização do *Visual Studio Code* como ambiente de desenvolvimento proporcionou uma experiência eficiente na

escrita e execução do código, permitindo a integração com bibliotecas externas e facilitando a depuração dos modelos. A abordagem metodológica adotada garantiu uma análise detalhada dos impactos da regressão LASSO e *Ridge*, contribuindo para a compreensão das vantagens e limitações de cada técnica (Hastie, 2009).

3.1 Dataset

O *Dataset* utilizado neste estudo consiste em uma série temporal composta por registros históricos de preços médios mensais de uma commodity agrícola ao longo de um período de doze meses. Os dados foram obtidos do Federal Reserve Bank of St. Louis na área de *Producer Price Index by Commodity: Farm Products: Citrus Fruits* (WPU011101), com um recorte do ano de 2024 (Producer Price Index by Commodity, 2025).

3.2 Desenvolvimento e validação

Para capturar relações não lineares presentes nos dados temporais, foi utilizado o pré-processamento com *Polynomial Features*, que transforma as variáveis originais em um espaço de variáveis polinomiais de grau definido, permitindo ao modelo aprender curvas e tendências mais complexas (HASTIE *et al.*, 2009). Essa técnica amplia a capacidade dos modelos lineares tradicionais ao incorporar termos polinomiais sem necessidade de alterar a estrutura básica do modelo, possibilitando um melhor ajuste das variações no preço da commodity ao longo do tempo. No Algoritmo 1 é apresentado o algoritmo para a geração no experimento.

X é dado por um vetor como variáveis explicativas, y é um vetor que são as variáveis explicadas (*target values*), α é o parâmetro de regularização que foi definido como $\alpha = 0.7$, *grau* remete a complexidade de transformação do pré-processamento *Polynomial Features* que foi definido como 3. Como saída são definidas como métricas de avaliação MAE e MSE apresentadas nas linhas 7 e 8 respectivamente no Algoritmo 1, sendo y o valor esperado (valor real) das variáveis explicadas, n é o número de elementos totais nas variáveis e a previsão do *Fold* de validação atribuídos na saída \hat{y} .

A validação dos modelos foi conduzida por meio da técnica de validação cruzada do tipo *k-Fold Cross-Validation*, com $k=10$, que consiste em dividir o conjunto de dados em 10 partes e iterativamente treinar o modelo em 9 partes enquanto é validado na parte restante, garantindo uma avaliação mais robusta da capacidade preditiva (Kohavi, 1995).

Algoritmo 1: Modelagem de Preços com *Ridge* e LASSO

Entrada

X : variável independente (tempo ou variável explicativa)

y : preços históricos da laranja

α : parâmetro de regularização

$grau$: grau polinomial (*Polynomial Features*)

k : número de *Folds* (Validação Cruzada)

Saída

MSE, MAE (Medidas de Avaliação)

Previsão de preços futuros

Início

```

1   $X_{poly} \leftarrow \text{PolynomialFeatures}(X, grau)$ 
2  Para cada fold em  $k$ -Fold( $k$ ):
3  Dividir dados em treino e teste
4  Para modelo em {Ridge, LASSO}:
5  Ajustar modelo com ( $X_{train\_poly}$ ,  $y_{train}$ ) usando  $\alpha$ 
6  Prever preços  $y_{pred}$  no conjunto de teste
7   $MSE_{fold} \leftarrow \frac{(y - \hat{y})^2}{n_{test}}$ 
8   $MAE_{fold} \leftarrow \frac{|y - \hat{y}|}{n_{test}}$ 
9   $MAE, MSE$ 

```

Fim

Fonte: Elaborado pelo autor.

Essa abordagem é amplamente adotada para mitigar o viés e a variância na estimativa do desempenho do modelo, sobretudo em *Datasets* com tamanho limitado, como o utilizado neste estudo. A abordagem de *Forward Chaining* consiste em selecionar uma parte do *Dataset*,

no caso do presente estudo *1-Fold*, e utilizar essa parte selecionada para prever a próxima parte, baseando nesse caso as previsões geradas na parte selecionada anterior utilizando a métrica temporal (Munaiseche; Kaparang; Rompas, 2018). As métricas principais para avaliação foram o Erro Quadrático Médio (MSE) e o Erro Absoluto Médio (MAE), que fornecem indicadores complementares da precisão das previsões, sendo o MSE mais sensível a grandes erros e o MAE mais interpretável na média das diferenças absolutas (Tibshirani, 1996).

Os resultados obtidos indicam que tanto os modelos *Ridge* quanto LASSO, quando combinados com transformações polinomiais, apresentaram desempenho superior em comparação às versões sem o uso dessas transformações, refletindo a importância de capturar a não linearidade dos dados para melhorar a predição do preço da commodity. A análise comparativa dos modelos foi realizada com base nas médias das métricas de erro extraídas da validação cruzada, permitindo selecionar os melhores parâmetros de regularização (α) e grau polinomial que equilibram o ajuste e a complexidade do modelo, conforme sugerido em estudos de regressão regularizada (Hastie, 2009).

4 RESULTADOS E DISCUSSÃO

Os resultados obtidos evidenciam que o uso da transformação polinomial no pré-processamento dos dados impacta diretamente no desempenho dos modelos de regressão *Ridge* e LASSO.

No que se refere ao método de validação, os modelos analisados por meio de validação cruzada com 10 divisões (*k-Fold*) demonstraram desempenho superior em relação à validação *Forward Chaining* (*1 - Fold*). A Tabela 1, referente ao desempenho das regressões *Ridge* e LASSO apresenta uma análise qualitativa das respostas obtidas por ambos os modelos, considerando os cenários com e sem aplicação da expansão polinomial, além dos métodos de validação *Forward Chaining* (*1-Fold*) e validação cruzada (*k-Fold*)

Tabela 1: Características modelos *Ridge* e LASSO

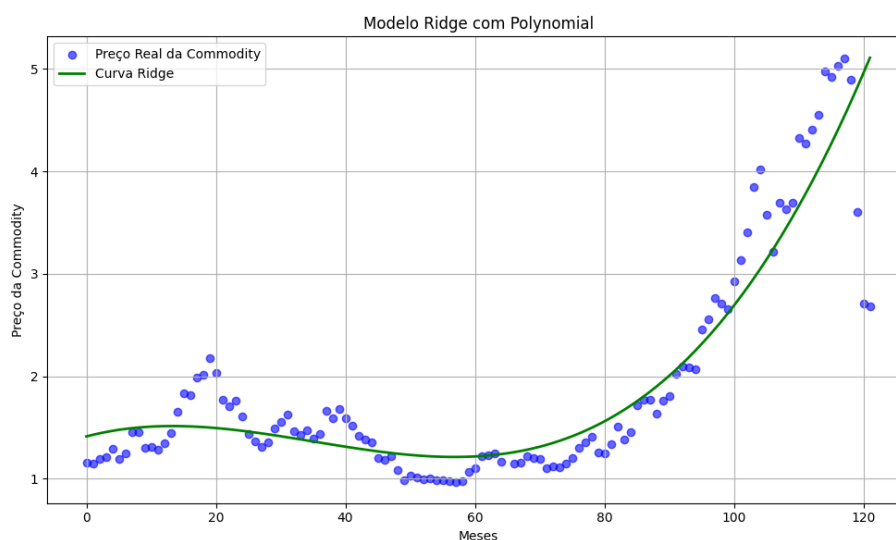
Discriminação dos resultados dos modelos de regressão <i>Ridge</i> e LASSO			
Modelo	Validação	Expansão Polinomial	Observações Técnicas
<i>Ridge</i>	<i>1-Fold</i>	Sem	Estável, sem seleção eficaz
<i>Ridge</i>	<i>1-Fold</i>	Com	Robusto, polinômio melhora desempenho.
<i>Ridge</i>	<i>k-Fold</i>	Sem	Generalização e estabilidade aprimoradas.
<i>Ridge</i>	<i>k-Fold</i>	Com	Desempenho superior, suaviza penalização.

LASSO	<i>l-Fold</i>	Sem	Reduz complexidade, seleciona variáveis.
LASSO	<i>l-Fold</i>	Com	Expansão reduz desempenho, sensível.
LASSO	<i>k-Fold</i>	Sem	Melhor otimização, modelo parcimonioso.
LASSO	<i>k-Fold</i>	Com	Validação útil, instabilidade persiste.

Fonte: Elaborado pelo autor.

Verificou-se que o modelo *Ridge* demonstrou maior resistência à multicolinearidade gerada pela transformação polinomial, especialmente quando associado à validação cruzada, resultando em estimativas mais consistentes e suavizadas. Em contrapartida, o modelo LASSO revelou maior sensibilidade a essa modificação, apresentando variações mais acentuadas quando a expansão foi aplicada, embora tenha se beneficiado substancialmente da validação cruzada, gerando modelos mais enxutos e com melhor capacidade de adaptação a novos dados. Assim, os achados reforçam evidências anteriores da literatura, como as de (Hastie, 2009), que destacam o comportamento distinto das técnicas de regularização diante da complexidade dos dados.

Gráfico 1: Desempenho do Modelo *Ridge* com *Cross-Fold* e *PolynomialFeatures*



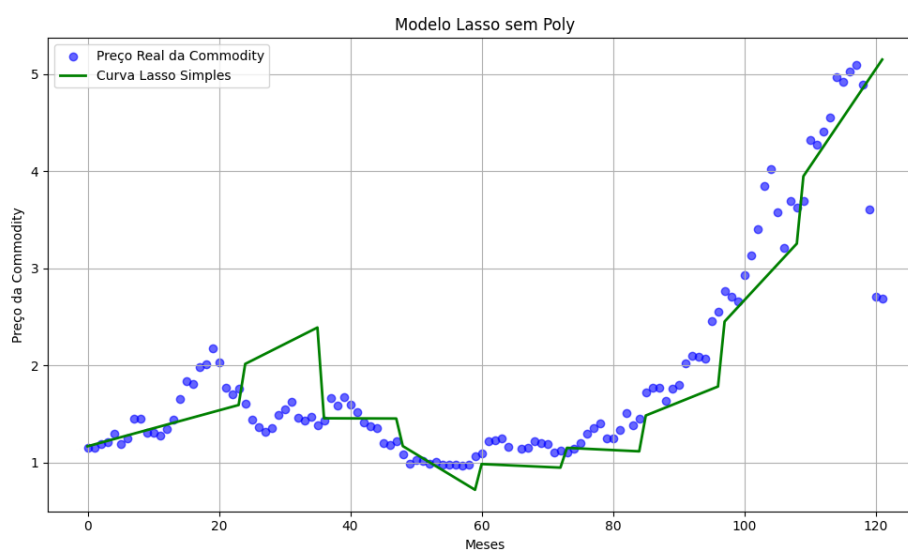
Fonte: Elaborado pelo autor.

No Gráfico 1 é apresentado os resultados da validação cruzada com *k-Fold* utilizando o modelo *Ridge* combinado com expansão polinomial (*PolynomialFeatures*), aplicada à previsão do preço da *commodity* em 12 meses. Os pontos azuis representam os dados reais, e a curva verde exibe as previsões ajustadas pelo modelo em cada *Fold* da validação. Observa-se que a combinação entre a regularização L2 do *Ridge* e a transformação polinomial permite ao modelo capturar com maior fidelidade a tendência crescente e as variações não lineares presentes na série histórica.

O Gráfico 2 apresenta a previsão dos preços da commodity laranja utilizando o modelo de regressão LASSO, sem a aplicação da transformação polinomial (*PolynomialFeatures*).

Verifica-se que os pontos azuis correspondem aos valores observados dos preços ao longo dos meses, enquanto a linha verde representa a estimativa gerada pelo modelo. A curva projetada apresenta flutuações abruptas e segmentadas, um comportamento típico do LASSO em cenários marcados por elevada multicolinearidade e ausência de enriquecimento de atributos. Essa resposta está relacionada à penalização L1 característica do LASSO, que tende a anular coeficientes, realizando uma seleção de variáveis mais rigorosa. Apesar de o modelo conseguir acompanhar a tendência geral dos dados, sua limitação em capturar relações não lineares afeta a suavidade da curva ajustada. Dessa forma, o desempenho observado reforça a relevância da transformação polinomial como estratégia para aprimorar a capacidade do modelo de refletir as variações reais dos preços, conforme apontado por Hastie (Hastie, 2009).

Gráfico 2: Desempenho do Modelo LASSO



Fonte: Elaborado pelo autor.

A análise dos resultados revela que o *Ridge* se mostra mais robusto e estável frente à transformação polinomial e diferentes métodos de validação, sendo o método mais indicado para cenários que envolvem pré-processamento polinomial e múltiplas validações. Já o LASSO é mais eficiente em reduzir a complexidade do modelo sem expansão polinomial e beneficia-se do uso da validação cruzada para calibragem fina dos parâmetros. Esses achados corroboram estudos anteriores sobre regularização em modelos lineares e a importância da escolha adequada de métodos conforme as características dos dados e objetivos da modelagem

(Pedregosa *et al.*, 2011; Hastie; Tibshirani; Friedman, 2009). Na tabela 2 é apresentado os erros absolutos gerados por todas as variações de experimentos abordadas no presente estudo.

Tabela 2: Erros modelos *Ridge* e LASSO

Modelo	Validação	Expansão Polinomial	MAE
LASSO	1-Fold	Não	1,57845238095238
LASSO	1-Fold	Sim	1,57845238095238
LASSO	<i>k</i> -Fold	Não	0,94904252399489
LASSO	<i>k</i> -Fold	Sim	1,10436099899091
<i>Ridge</i>	1-Fold	Não	1,36800000000000
<i>Ridge</i>	1-Fold	Sim	2,28600000000000
<i>Ridge</i>	<i>k</i> -Fold	Não	2,28896228289473
<i>Ridge</i>	<i>k</i> -Fold	Sim	0,63023307668421

Fonte: Elaborado pelo autor.

5 CONCLUSÃO

Durante o desenvolvimento deste trabalho, enfrentaram-se desafios técnicos e conceituais, principalmente relacionados ao tratamento dos dados e à escolha dos métodos de modelagem. A transformação polinomial exigiu atenção especial à multicolinearidade, o que demandou ajustes cuidadosos nos parâmetros de regularização.

A aplicação dos modelos *Ridge* e LASSO revelou comportamentos distintos. O *Ridge* demonstrou maior estabilidade frente aos dados transformados, enquanto o LASSO se destacou pela capacidade de simplificar o modelo, eliminando variáveis irrelevantes e reduzindo o risco sobre ajuste.

A validação cruzada com múltiplos *Folds* foi essencial para garantir a generalização dos modelos. Essa abordagem permitiu calibrar os hiperparâmetros de forma robusta, contribuindo para resultados mais confiáveis e alinhados às boas práticas em aprendizado de máquina.

REFERÊNCIAS

EMBRAPA. 2025. Disponível em: <https://www.embrapa.br/en/international>. Acesso em: 22 set. 2025.

FABOZZI, F. J.; DRAKE, P. P. **Finance: capital markets, financial management, and investment management.** [S. l.]: John Wiley & Sons, 2009. Disponível em: https://books.google.com/books?hl=ptBR&lr=&id=IqUXCNOJiq8C&oi=fnd&pg=PP15&dq=Finance:+Capital+Markets,+Financial+Management,+and+Investment+Management&ots=YoEhdYnglk&sig=d_kVr3iYGOBHM0oZc7r-LXA7mo. Acesso em: 22 set. 2025.

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS. 2025. Disponível em: <https://www.fao.org/home/en>. Acesso em: 22 set. 2025.

GEMAN, H. **Commodities and commodity derivatives: modeling and pricing for agriculturals, metals and energy.** [S. l.]: John Wiley & Sons, 2005. Disponível em: https://books.google.com/books?hl=ptBR&lr=&id=QEzYEAAAQBAJ&oi=fnd&pg=PR11&dq=Commodities+and+Commodity+Derivatives:+Modelling+and+Pricing+for+Agriculturals,+Metals+and+Energy&ots=k6Kb-6Lg_i&sig=NM8b_laQrsDdRIe8Ao5Yj_iCRqA. Acesso em: 22 set. 2025.

HASTIE, T. **The elements of statistical learning: data mining, inference, and prediction.** [S. l.]: Springer, 2009.

HOERL, A. E.; KENNARD, R. W. Ridge Regression — 1980: Advances, Algorithms, and Applications. **American Journal of Mathematical and Management Sciences**, [s. l.], v. 1, n. 1, p. 5–83, jan. 1981. <https://doi.org/10.1080/01966324.1981.10737061>.

HULL, J. **Risk management and financial institutions, Web Site.** [S. l.]: John Wiley & Sons, 2012. v. 733, . Disponível em: <https://books.google.com/books?hl=ptBR&lr=&id=ixLD1gjPfoMC&oi=fnd&pg=PR19&dq=Risk+Management+and+Financial+Institutions&ots=5bIsrwjIWx&sig=qn4jomO0KlaLD6SC98Q8d2o2PGM>. Acesso em: 22 set. 2025.

KOHAVI, R. **A study of cross-validation and bootstrap for accuracy estimation and model selection.** 14., 1995. Ijcai [...]. [S. l.]: Montreal, Canada, 1995. v. 14, p. 1137–1145. Disponível em: https://www.researchgate.net/profile/RonKohavi/publication/2352264_A_Study_of_Cross_Validation_and_Bootstrap_for_Accuracy_Estimation_and_Model_Selection/links/02e7e51bc14c5e91c00000/A-Study-of-Cross-Validation-and-Bootstrap-for-Accuracy-Estimation-and-Model-Selection.pdf. Acesso em: 22 set. 2025.

MUNAISECHE, C. P. C.; KAPARANG, D. R.; ROMPAS, P. T. D. **An Expert system for diagnosing eye diseases using forward chaining method.** 306., 2018. IOP Conference Series: Materials Science and Engineering [...]. [S. l.]: IOP Publishing, 2018. v. 306, p. 012023. Disponível em: <https://iopscience.iop.org/article/10.1088/1757-899X/306/1/012023/meta>. Acesso em: 25 set. 2025.

PRODUCER PRICE INDEX BY COMMODITY: FARM PRODUCTS: CITRUS FRUITS. 10 set. 2025. Disponível em: <https://fred.stlouisfed.org/series/WPU011101>. Acesso em: 22 set. 2025.

RONCORONI, A.; FUSAI, G.; CUMMINS, M. **Handbook of multi-commodity markets and products: Structuring, trading and risk management.** [S. l.]: John Wiley & Sons, 2015. Disponível em: <https://books.google.com/books?hl=ptBR&lr=&id=UC2kBgAAQBAJ&oi=fnd&pg=PR19&dq=Handbook+of+MultiCommodity+Markets+and+Products:+Structuring,+Tr>

ading+and+Risk+Management&ots=_37ZGwyb42&sig=8It65EdWrP8RX6T3ISCZ6YKGnU
Q. Acesso em: 22 set. 2025.

TIBSHIRANI, R. Regression shrinkage and selection via the lasso. **Journal of the Royal Statistical Society Series B: Statistical Methodology**, [s. l.], v. 58, n. 1, p. 267–288, 1996. .