



SAMUEL HENRIQUE GUIMARÃES BRAGA

**DESENVOLVIMENTO DE UM MODELO DE
APRENDIZADO DE MÁQUINA PARA
PREVISÃO DO PREÇO DO AÇÚCAR NA BOLSA
DE VALORES**

LAVRAS – MG

2023

SAMUEL HENRIQUE GUIMARÃES BRAGA

**DESENVOLVIMENTO DE UM MODELO DE APRENDIZADO DE
MÁQUINA PARA PREVISÃO DO PREÇO DO AÇÚCAR NA BOLSA DE
VALORES**

Trabalho de conclusão de curso apresentado à
Universidade Federal de Lavras, como parte das
exigências do Programa de Graduação, área de
engenharia de controle e automação, para a obtenção
do título de Bacharel.

Prof. DSc. Danilo Alves de Lima

Orientador

LAVRAS – MG

2023

**Ficha catalográfica elaborada pela Coordenadoria de Processos Técnicos
da Biblioteca Universitária da UFLA**

Braga, Samuel Henrique Guimarães

Desenvolvimento de um Modelo de Aprendizado de Máquina
para Previsão do Preço do Açúcar na Bolsa de Valores / Samuel
Henrique Guimarães Braga. – Lavras : UFLA, 2023.

55 p. :

TCC (graduação)–Universidade Federal de Lavras, 2023.

Orientador: Prof. DSc. Danilo Alves de Lima.

Bibliografia.

1. Machine Learning. 2. Previsão de Preço. 3. Bolsa de
Commodities. I. de Lima, Danilo Alves. II. Título.

CDD-808.066

Dedico este trabalho à minha família, fonte inesgotável de amor, apoio e inspiração. A cada membro que compartilhou comigo esta jornada acadêmica, especialmente aos meus pais, cujo sacrifício e encorajamento foram a força propulsora por trás desta conquista. Dedico também a todos os amigos e mentores que, com paciência e sabedoria, contribuíram para o meu crescimento intelectual e pessoal. Este trabalho é uma homenagem ao legado daqueles que me motivaram a buscar o conhecimento e a excelência.

AGRADECIMENTOS

Expresso minha sincera gratidão a todas as pessoas e instituições que possibilitaram a concretização deste trabalho. Inicialmente, desejo agradecer ao meu orientador, professor Danilo Alves de Lima e ao professor Arthur de Miranda Neto, por sua orientação exemplar durante meus anos no NLMT. Seu apoio constante e insights valiosos não apenas moldaram este trabalho, mas também contribuíram significativamente para a minha formação acadêmica.

Gostaria de estender meu reconhecimento à minha família, cujo apoio incondicional se revelou essencial ao longo de todo o processo. Agradeço também aos meus amigos e colegas, cujo compartilhamento de conhecimento, experiências e estímulo foram fundamentais para meu crescimento acadêmico.

Por último, expresso minha gratidão a todos que, de alguma maneira, colaboraram nesta jornada. Este trabalho é resultado de um esforço coletivo, e minha apreciação reflete o valor que atribuo a cada pessoa e recurso envolvido.

*Se você não acabar com suas distrações,
suas tristezas vão acabar com seus objetivos.*

(Joel Jota.)

RESUMO

Atualmente, o Brasil desempenha um papel significativo no cenário global do comércio de açúcar, sendo um proeminente exportador que movimenta safras bilionárias. As empresas envolvidas na exportação desse produto buscam incorporar tecnologias avançadas, notadamente modelos de aprendizado de máquina, para antecipar variações nos preços do açúcar e mitigar a volatilidade do mercado. A complexidade desse empreendimento é ampliada devido a fatores externos imprevisíveis e à limitação de acesso a dados completos e precisos. Este trabalho apresenta a concepção e implementação de um modelo de aprendizado de máquina baseado em redes neurais, destinado a prever as discrepâncias entre os preços do açúcar nas bolsas de Nova York e Londres. Essa abordagem visa proporcionar *insights* cruciais para as tomadas de decisão das empresas exportadoras de açúcar no Brasil. O enfoque adotado é de natureza minimalista, concentrando-se no histórico de preços, preços futuros nas telas de negociação e dados relacionados à oferta e demanda global. Os resultados obtidos indicam que o histórico de preços do açúcar, por si só, é suficiente para a construção de um modelo de aprendizado de máquina, evidenciando erros médios próximos a 10%. Esta constatação sugere que a correlação entre os dados de oferta, demanda e preços futuros não são capazes de proporcionar melhorias substanciais no desempenho do modelo e, em alguns casos, pode até comprometê-lo. Adicionalmente, destaca-se a superioridade do modelo LSTM Residual em relação ao modelo LSTM na previsão de preços para períodos mais extensos.

Palavras-chave: Machine Learning; Previsão de Preço; Bolsa de Commodities

ABSTRACT

Currently, Brazil plays a significant role in the global sugar trade scenario, being a prominent exporter that moves billion-dollar harvests. Companies involved in exporting this product seek to incorporate advanced technologies, notably machine learning models, to anticipate variations in sugar prices and mitigate market volatility. The complexity of this undertaking is magnified due to unpredictable external factors and limited access to complete and accurate data. This work presents the design and implementation of a machine learning model based on neural networks, designed to predict discrepancies between sugar prices on the New York and London stock exchanges. This approach aims to provide crucial *insights* for the decision-making of sugar exporting companies in Brazil. The approach adopted is minimalist in nature, focusing on historical prices, futures prices on trading screens and data related to global supply and demand. The results obtained indicate that the history of sugar prices, in itself, is sufficient to build a machine learning model, showing average errors close to 10%. This finding suggests that the correlation between supply, demand and future price data is not capable of providing substantial improvements in the model's performance and, in some cases, may even compromise it. Additionally, the superiority of the LSTM Residual model in relation to the LSTM model in price forecasting for longer periods stands out.

Keywords: Machine Learning; Price Prediction; Commodity Exchange.

LISTA DE FIGURAS

Figura 3.1 – Conexão retroativas do modelo RNN.	32
Figura 3.2 – Estrutura do modelo LSTM.	33
Figura 4.1 – Correlação entre o <i>white premium</i> e futuras telas.	36
Figura 4.2 – Correlação entre o <i>white premium</i> e os dados de produção de açúcar total e alta qualidade.	37
Figura 4.3 – Correlação entre o <i>white premium</i> e os dados de produção de açúcar bruto e baixa qualidade.	37
Figura 4.4 – Correlação entre o <i>white premium</i> e os dados de consumo e exportação.	38
Figura 4.5 – Correlação entre o <i>white premium</i> e os dados de importação e estoque.	39
Figura 4.6 – Correlação entre o <i>white premium</i> e os dados de importação e exportação.	40
Figura 4.7 – Correlação entre o <i>white premium</i> e a duração dos estoque. . .	40
Figura 5.1 – Previsões realizadas com o modelo LSTM treinado com dados de S&D e histórico de preço.	43
Figura 5.2 – Previsões realizadas com o modelo LSTM Residual treinado com dados de s&d e histórico de preço.	44
Figura 5.3 – Previsões realizadas com o modelo LSTM treinado com dados de futuras telas e histórico de preço.	46
Figura 5.4 – Previsões realizadas com o modelo LSTM Residual treinado com dados de futuras telas e histórico de preço.	47
Figura 5.5 – Previsões realizadas com o modelo LSTM Residual treinado com todos os dados.	48
Figura 5.6 – Previsões realizadas com o modelo LSTM Residual treinado apenas com dados históricos de preço.	49

LISTA DE TABELAS

Tabela 4.1 – Teste de causalidade de granger com dados de produção. . . .	38
Tabela 4.2 – Teste de causalidade de granger com dados de S&D.	39
Tabela 5.1 – Resultados dos testes com o modelo LSTM treinado com dados de S&D e histórico de preço.	44
Tabela 5.2 – Resultados dos testes com o modelo LSTM Residual treinado com dados de S&D e histórico de preço.	45
Tabela 5.3 – Resultados dos testes com o modelo LSTM treinado com dados de futuras telas e histórico de preço.	46
Tabela 5.4 – Resultados dos testes com o modelo LSTM Residual treinado com dados de futuras telas e histórico de preço.	47
Tabela 5.5 – Delta entre os erros percentuais médios do modelo com todos os dados e o modelo com apenas o histórico de preço do <i>white premium</i>	47
Tabela 5.6 – Resultados dos testes com o modelo LSTM Residual treinado com todos os dados.	48
Tabela 5.7 – Resultados dos testes com o modelo LSTM Residual treinado apenas com dados históricos de preço.	49

SUMÁRIO

1	INTRODUÇÃO	19
1.1	Objetivo	21
1.2	Estrutura do Trabalho	22
2	Definição do Problema	23
2.1	Preços do NY#11 e Londres	23
2.2	Dados de S&D Globais	24
2.3	Dados em Conjunto	25
3	Revisão da Literatura	27
3.1	Influências de S&D nos preços do açúcar	27
3.2	Influências de contratos futuros	28
3.3	Coefficiente de Pearson	29
3.4	Teste de Causalidade de Granger	30
3.5	Previsão de Preços de Commodities	31
4	Metodologia	35
4.1	Modelagem dos Dados de Preço	35
4.1.1	Correlação Entre o Preço do White Premium e Futuras Telas	35
4.1.2	Correlações entre o White Premium e os Dados de S&D	36
4.2	Modelo de Rede Neural	41
5	Resultados	43
5.1	Modelos Treinados com Dados de S&D	43
5.2	Modelos Treinados com os Preços de Futuras Telas	45
5.3	Melhor Modelo	45
6	CONCLUSÃO	51
	REFERÊNCIAS	53

1 INTRODUÇÃO

O açúcar tem raízes profundas na história da humanidade, tendo sua origem datada por volta de 500 a.C. na Ásia, mais especificamente na Índia. Relatos indicam que os indianos produziam um tipo de mel proveniente do caldo da cana de açúcar (MINTZ, 1985). No Brasil, o açúcar teve um forte papel durante a colonização, sendo trazido pelos portugueses em 1532, instituindo grandes plantações e engenhos. No final do século XVI havia cerca de 140 engenhos funcionando em Pernambuco (SCHWARCZ LILIA MORITZ E STARLING, 2015).

Atualmente, o Brasil representa grande parte do comércio global de açúcar, sendo frequentemente reconhecido como o maior exportador de açúcar. Em 2022, chegou a exportar cerca de 27,29 milhões de toneladas de açúcar, movimentando aproximadamente 11 bilhões de dólares (REGINA, 2023). Entretanto, a indústria da cana de açúcar não se limita apenas ao açúcar, a produção de biocombustíveis, como o etanol, e a queima do bagaço para geração de energia também representam uma porcentagem significativa desse setor. Dessa forma, o setor sucroenergético movimenta aproximadamente 100 bilhões de reais ao ano, o equivalente a 2% do PIB do Brasil (UNICA, 2019). Isso deve-se, em grande parte, às condições climáticas favoráveis e à vasta extensão de terras cultiváveis, particularmente nas regiões tropicais do país. Como resultado, a produção brasileira de açúcar é altamente competitiva em termos de volume e qualidade.

O mercado de exportação e importação de açúcar é dividido em dois grandes tipos, sendo eles o açúcar bruto (*Raw Sugar*), comercializado na bolsa de Nova York, e o açúcar refinado de alta qualidade (*High Quality*), comercializado na bolsa de Londres. Assim, o comércio global de açúcar gira em torno de países que produzem bruto ou alta qualidade para exportação, países que importam bruto para refinar e exportar alta qualidade e países importadores de alta qualidade.

O açúcar bruto, por ser um tipo de menor qualidade, é mais fácil de ser produzido, porém, é fortemente influenciado pela oferta e demanda dos grandes

países refinadores, como é o caso da Índia. Porém, a produção do açúcar de alta qualidade demanda mais esforço, energia e custos, sendo necessário várias etapas adicionais na indústria para remoção de impurezas e clareamento. Entretanto, o açúcar de alta qualidade é comercializado por um preço maior, o que pode compensar o esforço para refiná-lo.

No Brasil a grande maioria do açúcar que é exportado é do tipo bruto, em 2022 representou 88% de todo açúcar exportado, sendo uma parcela significativa de todo o açúcar comercializado no mundo (UNICA, 2019). Porém, também é exportado uma alta quantidade de açúcar refinado. A escolha da proporção entre esses dois tipos é fortemente influenciada pela diferença de preço (delta) do açúcar na bolsa de Nova York e Londres, esse delta é comumente chamado de white premium. Basicamente, se o valor agregado ao açúcar refinado de alta qualidade for o suficiente para arcar com os custos de refinaria, e ainda assim, gerar um lucro acima do que seria gerado pela exportação do açúcar bruto, as empresas exportadoras de açúcar irão optar por exportar mais açúcar refinado de alta qualidade.

Por isso, as empresas exportadoras têm investido cada vez mais em novas tecnologias que deem suporte nessas tomadas de decisões. A utilização de modelos de aprendizado de máquina (machine learning) tem se tornado cada vez mais comuns nesse cenário, gerando previsões de preço do açúcar na bolsa (AMEUR; BOUBAKER; FTITI, 2023). Previsões assertivas podem garantir que as empresas tenham a possibilidade de planejar suas exportações de acordo com as flutuações de preços ou até se protegerem da volatilidade do mercado.

Porém, desenvolver uma ferramenta capaz de prever os preços com exatidão não é uma tarefa fácil, pois o mercado de commodities é influenciado por vários fatores externos imprevisíveis, como eventos climáticos extremos, desastres naturais, políticas governamentais, crises geopolíticas e eventos imprevistos que podem ter um impacto imediato nos mercados (SCHMIEG, 1993), trazendo uma alta volatilidade para o mercado. A relação entre as commodities também gera

influência nos preços em bolsa, como as variações nos preços do petróleo que podem aumentar os custos de produção e transporte. Ademais, outros pontos que podem afetar o preço de commodities na bolsa são fatores psicológicos e comportamentais, como otimismo, especulação, notícias e sentimento do mercado. Dessa forma, esses elementos intangíveis são difíceis de modelar e prever com precisão.

Entretanto, o maior empecilho para conseguir criar um modelo de previsão, não está ligado ao mercado e sim à disponibilidade de dados, uma vez que, nem sempre há dados completos e precisos disponíveis para todas as variáveis que afetam os preços das commodities. Além disso, a qualidade dos dados históricos pode variar, o que pode impactar na precisão dos modelos de previsão. Sendo assim, a construção de um banco de dados com informações relevantes para a previsão desses preços é um trabalho árduo para as empresas de exportação de commodities, sendo considerados dados sensíveis e que não são disponibilizados ao público.

Este trabalho visa desenvolver um modelo de machine learning utilizando técnicas de redes neurais conhecidas para prever a diferença entre o preço do açúcar na bolsa de Nova York e Londres, comumente chamado de *White Premium*, e assim, gerar *insights* e suporte para a decisão de empresas exportadoras de açúcar no Brasil. Como citado anteriormente, existe uma grande dificuldade de acesso aos dados de commodities, com isso, foi adotado uma abordagem minimalista focando apenas nas variáveis de preço, produção, estoque, consumo, importação e exportação de açúcar global. Este modelo faz parte de um experimento realizado para a empresa Tereos Açúcar e Energia Brasil, os dados foram fornecidos pela mesma, portanto, não foi possível a disponibilização deles neste documento público.

1.1 Objetivo

O objetivo deste estudo é desenvolver modelos de aprendizado de máquina utilizando técnicas de redes neurais e avaliar se os dados utilizados proporcionam

suporte para um erro médio inferior a 10%. O processo de alcançar esse objetivo envolve as seguintes etapas:

- Modelar os dados de maneira a identificar correlações mais robustas com a curva de preços do açúcar.
- Avaliar os modelos de redes neurais, tanto LSTM quanto LSTM Residual, para compreender qual deles melhor representa a dinâmica da curva de preços do açúcar.
- Experimentar diferentes variáveis de entrada a fim de encontrar a combinação mais eficaz para um modelo com o menor erro médio possível.

1.2 Estrutura do Trabalho

Este trabalho foi estruturado de maneira a proporcionar uma compreensão clara e lógica dos elementos abordados. O artigo segue uma organização em diversos capítulos, cada um contribuindo para uma compreensão abrangente do tema. No Capítulo 2, o problema é definido, além de serem explicados os dados utilizados no modelo. O Capítulo 3 oferece uma revisão da literatura, fundamentando a escolha dos dados e referenciando trabalhos similares. No Capítulo 4, são apresentadas as técnicas e métodos empregados na modelagem dos dados. Os resultados obtidos com os modelos propostos são divulgados no Capítulo 5, enquanto o Capítulo 6 traz uma conclusão que compara as expectativas iniciais com os resultados alcançados.

2 DEFINIÇÃO DO PROBLEMA

Este capítulo explica o problema abordado, com os dados utilizados para o modelo de aprendizado de máquina, apresentando as correlações e hipóteses que serão testadas no decorrer do trabalho.

2.1 Preços do NY#11 e Londres

O NY#11 é um dos contratos mais negociados de açúcar em bolsas de commodities, ele é oferecido pela Intercontinental Exchange (ICE) e é usado para negociar açúcar bruto. Esses contratos possuem períodos fixos de vencimento no ano, onde a empresa é obrigada a entregar ou receber o açúcar, dependendo de sua posição no mercado, sendo comprador ou vendedor.

As negociações costumam funcionar entre os dois meses anteriores aos meses de vencimento, esses períodos de três meses, sendo dois para negociar e um para entregar ou receber o açúcar, são comumente chamados de telas de negociações.

Como em qualquer bolsa de valores, o preço do NY#11 é um reflexo dos contratos que estão sendo negociados durante o dia, porém, não necessariamente uma empresa precisa negociar contratos de açúcar na tela mais próxima, a maioria dos contratos são negociados em telas futuras. O preço em telas futuras são reflexos de especulação e refletem como o mercado acha que será o preço do açúcar naquele período. Uma empresa pode negociar seus contratos por achar que o valor está bom, porém no momento de executar o contrato a empresa pode ter perdido ou ganhado dinheiro, dependendo do valor real do NY#11 naquele momento.

A bolsa de Londres segue os mesmos princípios, tendo diferença apenas no tipo de açúcar e telas de negociações. O açúcar comercializado é o branco de alta qualidade e suas telas de negociações são em menor quantidade no ano, trazendo um maior período de negociação.

Estes dados serão utilizados para explorar a hipótese de que, ao desconsiderar outros dados potencialmente influentes no valor do "*white premium*", como dados meteorológicos, especulações, medidas governamentais, entre outros, ainda é possível desenvolver um modelo com uma margem de erro média inferior a 10%, utilizando apenas a curva de preço atual do açúcar e os preços de futuros contratos.

2.2 Dados de S&D Globais

Os dados de “S&D Globais” se referem aos dados de oferta e demanda (do inglês *Source and Demand*) global de açúcar. Sendo mais específico, ele é constituído pelos valores de importação, exportação, estoque inicial, estoque final, produção e consumo desse produto no mundo. Esses dados são divididos por meses, países e tipos de açúcar (*High-Quality, Low-Quality e Raw*).

Nem sempre esses dados estão corretos e é mais fácil tê-los em termos de açúcar total, como por exemplo a quantidade total de açúcar que o Brasil exportou em 2022. A maioria dessas bases são construídas de fora para dentro, tendo os valores totais de um país e estimando a quantidade de cada tipo de açúcar. No entanto ainda assim, são dados importantes que podem descrever o papel de cada país no mercado de açúcar global e como eles podem estar influenciando o preço do açúcar na bolsa.

Outra hipótese que este documento visa explorar é como os dados de S&D de um país podem servir para prever o preço do açúcar, compreendendo, por exemplo, como o Brasil influencia o preço do açúcar em anos ou meses em que tem uma maior quantidade de açúcar bruto sendo exportado. O mesmo reflete ao açúcar de alta qualidade, como a influência dos Estados Unidos da América, um dos maiores compradores de açúcar branco de alta qualidade, pode aumentar ou diminuir o preço do *white premium* no mercado.

2.3 Dados em Conjunto

Todos esses dados de oferta e demanda podem ser analisados em conjunto para identificar novas variáveis que apresentem uma melhor correlação com a curva de preço do açúcar. Uma abordagem interessante é a divisão do estoque pelo consumo de um país, o que nos permite determinar a quantidade de meses ou anos que esses estoques durarão. Como hipótese, podemos sugerir que um país pode assumir um papel mais ativo quando seus estoques estiverem próximos do esgotamento.

Os preços atuais e de futuras telas podem servir para dar um norte de como o mercado especula que será a curva de preços dos próximos 12 meses, ao mesmo tempo os dados de S&D podem servir para tentar prever futuros impactos que geram anomalias nas curvas de preço. Por exemplo, um país como a Rússia ou os EUA, ao passarem meses aumentando seus estoques de açúcar, geram grandes impactos no preço do açúcar.

3 REVISÃO DA LITERATURA

Este capítulo apresenta uma revisão de literatura introduzindo uma evolução cronológica sobre o assunto e citando as metodologias mais utilizadas para previsão de preço de commodities.

3.1 Influências de S&D nos preços do açúcar

A dinâmica complexa do mercado global de açúcar é influenciada por diversos fatores interconectados. A produção abundante, conforme observado por (AHLFELD, 2010), exerce uma pressão decrescente nos preços, enquanto a escassez, frequentemente desencadeada por condições climáticas adversas em países-chave, pode resultar em aumentos abruptos nos valores. Essa volatilidade, essencial para a compreensão do cenário açucareiro mundial, desempenha um papel crucial no gerenciamento de riscos e nas decisões estratégicas de investidores, produtores e governos.

No âmbito das determinantes apontadas por (CERMAK, 2009), (TODD, 2010), (MAITAH; SMUTKA, 2018), e (BABUNĚK, 2016), a oferta e a demanda, aliadas às condições climáticas, emergem como fatores preponderantes. Esses elementos exercem um impacto direto nos níveis de produção e nos estoques de açúcar, adicionando uma camada de complexidade à equação do mercado açucareiro.

O equilíbrio entre a oferta global e a demanda de açúcar assume uma posição central como indicador-chave dos preços globais (TODD, 2010). A ocorrência de desequilíbrios, com a demanda superando a oferta, tende a alavancar os preços devido à escassez.

Por sua vez, MAITAH e SMUTKA (2018) destacam um fator adicional, evidenciando a influência das flutuações nos estoques de açúcar, muitas vezes desencadeadas por corridas de mercado por especuladores. Isso sublinha a crescente

complexidade do mercado de açúcar, onde movimentos especulativos podem exercer impacto significativo nos preços.

A interrelação entre estoques e a população revela que a disponibilidade de açúcar está intrinsicamente ligada à capacidade de atender à demanda global (BABUNĚK, 2016). Entretanto, ele também observa que as mudanças em países individuais ou pequenos grupos de países têm um impacto limitado nos preços globais, enfatizando a natureza complexa e globalizada desse mercado.

3.2 Influências de contratos futuros

A antiga teoria da pressão de cobertura (HIRSHLEIFER, 2015; HIRSHLEIFER, 1990) afirma que existem dois tipos de participantes no mercado futuro de commodities, sendo os *traders de hedge* e *traders* especulativos. Os *traders de hedge* são geralmente produtores de matérias-primas que buscam proteger-se contra a queda dos preços desses ativos para fins comerciais. Para tanto, detêm posições curtas em contratos futuros, o que lhes permite garantir preços previsíveis para suas mercadorias, minimizando riscos e incertezas associados às flutuações de preços. Por outro lado, os especuladores não possuem uma exposição direta à produção de matérias-primas e buscam lucrar com as variações de preços por meio de posições longas em contratos futuros. Estão dispostos a assumir riscos e são motivados pelo potencial de obter retornos financeiros.

Apesar dessas distinções, permanece incerto o vínculo direto entre a influência desses participantes nos contratos futuros e as flutuações imediatas nos preços das commodities. Conforme apontado por (BOHL; STEFAN, 2020), os indicadores macroeconômicos emergem como os principais influenciadores que delineiam as curvas de preço das commodities. Contrariamente, (BOHMANN; MICHAYLUK; PATEL, 2019) destaca a especulação como um indicador robusto na previsão dos preços desses ativos. Nesse contexto, a complexidade da interação entre diferentes fatores implica que, embora teorias delineiem papéis distintos

para os *traders*, a compreensão plena do panorama exige uma abordagem multifacetada, considerando a dinâmica entre indicadores econômicos e especulativos. Essa relação dinâmica contribui para a riqueza e a complexidade inerentes ao mercado de commodities.

3.3 Coeficiente de Pearson

O coeficiente de Pearson, também reconhecido como coeficiente de correlação, constitui uma medida estatística que quantifica o grau de relacionamento linear entre duas variáveis. Concebido pelo estatístico Karl Pearson no início do século XX (STANTON, 2001), esse coeficiente é extensamente utilizado em estatística e ciência de dados para avaliar a intensidade e a direção da associação entre duas variáveis. O cálculo do coeficiente de Pearson envolve a análise da covariância entre as duas variáveis em relação às variâncias individuais de cada uma (PARANHOS et al., 2014). A fórmula do coeficiente de Pearson é delineada da seguinte forma:

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (3.1)$$

Os termos x_i e y_i representam os valores individuais das variáveis, enquanto \bar{x} e \bar{y} indicam suas médias, já o coeficiente de correlação "r" varia de -1 a 1, proporcionando informações sobre a natureza da relação. Quando "r" é igual a 1, existe uma correlação positiva perfeita, indicando que, à medida que uma variável aumenta, a outra também aumenta de forma linear. Por outro lado, quando "r" é igual a -1, há uma correlação negativa perfeita, sugerindo que, conforme uma variável aumenta, a outra diminui linearmente. Quando "r" é próximo de 0, não há uma relação linear aparente entre as variáveis. O coeficiente de correlação de Pearson é comumente utilizado para analisar relações lineares e é relevante em

contextos de modelagem estatística e machine learning, fornecendo insights sobre a dependência entre variáveis contínuas.

3.4 Teste de Causalidade de Granger

O teste de causalidade de Granger (GRANGER, 1980), uma técnica estatística fundamental aplicada em diversas disciplinas, incluindo economia e finanças, visa avaliar a relação de causalidade entre séries temporais. Esse teste fundamenta-se na premissa de que, se X causa Y , então informações sobre os valores passados de X deveriam ter a capacidade de prever o comportamento futuro de Y . O procedimento implica na modelagem das duas séries temporais em relação aos seus próprios valores anteriores por meio de modelos autorregressivos (AR) (SHOJAIE; FOX, 2022). Posteriormente, é realizada uma comparação estatística dos modelos de Y , com e sem a inclusão dos valores passados de X como variáveis independentes.

Os resultados do teste são expressos mediante estatísticas como o valor F e o valor- p . Um valor- p reduzido indica que a inclusão de X é estatisticamente relevante na previsão de Y , sugerindo a existência de causalidade. Em contrapartida, um valor- p elevado aponta a ausência de evidências estatísticas de causalidade, indicando que X não causa Y .

O coeficiente de Pearson, utilizado no experimento, foi essencial para avaliar se as variáveis testadas não apresentam correlação meramente por acaso, mas sim se exercem uma influência significativa na variável medida. Este coeficiente, ao quantificar a relação linear entre as variáveis, permite uma análise mais robusta, proporcionando insights sobre a natureza e a intensidade da associação entre os fatores estudados. Dessa forma, sua aplicação contribuiu para assegurar que as conclusões derivadas do experimento se baseassem em relações estatisticamente significativas, fortalecendo a validade e a confiabilidade dos resultados obtidos.

3.5 Previsão de Preços de Commodities

Um dos primeiros métodos pioneiros de previsão de preços de commodities foi a análise de regressão, originalmente desenvolvida por Sir Francis Galton, um eminente estatístico britânico (ETHINGTON; THOMAS; PIKE, 2002). Galton aplicou esse método ao estudar a relação entre a altura paterna no Reino Unido. Posteriormente, em 1917, Henry Ludwell Moore fez uma notável contribuição ao avançar ainda mais na análise de regressão, criando um modelo de regressão linear específico para prever os preços do algodão (YULE, 1918).

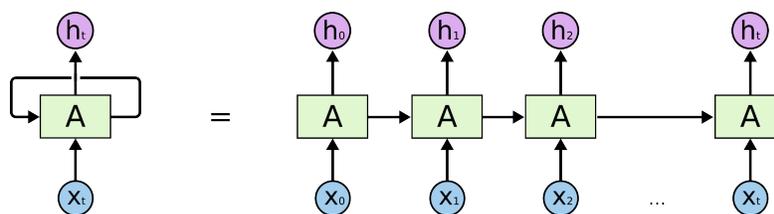
Até o presente momento, os modelos de regressão linear mantêm-se como uma ferramenta de previsão amplamente adotada. Tais modelos pressupõem que a variável alvo apresenta uma forte correlação com as variáveis explicativas e uma relação linear. Embora esses modelos sejam frequentemente empregados para previsões a curto e médio prazo, é importante destacar que, quando os dados exibem padrões não lineares ou alta volatilidade, pode ser necessário considerar alternativas mais apropriadas.

Nesse contexto, o campo da aprendizagem de máquina tem ganhado proeminência nos últimos anos, marcado pelo desenvolvimento de diversas abordagens e algoritmos que expandem as fronteiras do que é possível realizar com dados e modelos. As redes neurais, em particular, destacam-se como pilares fundamentais nesse domínio, desempenhando um papel crucial em diversas aplicações. Dentro desse cenário, vários exemplos notáveis merecem destaque. Por exemplo, a utilização de redes neurais em conjunto com a técnica de espectro singular (SSA) para decompor a curva de preço (WANG; LI, 2018), a implementação de um modelo de topologia de rede conjunta e normalização regular para prever o preço bruto do óleo de palma (GUNAWAN; KHODRA; HARLILI, 2013), além da aplicação de redes neurais perceptron de multicamadas (MLP) com o algoritmo de otimização de baleia (WOA) para a previsão de flutuações no preço do ouro (ALAMEER et al., 2019). Esses são apenas alguns exemplos que ilustram a versatilidade e o

impacto significativo das abordagens de aprendizagem de máquina em diferentes contextos e aplicações.

As Redes Neurais Recorrentes (RNN) (HOCHREITER; SCHMIDHUBER, 1997) e (GRAVES, 2012), são conhecidas por sua capacidade de lidar com dados sequenciais, tornando-as valiosas em tarefas como análise de séries temporais, tradução automática e processamento de linguagem natural. A característica chave é o loop recorrente, onde o estado oculto atual X_t é alimentado de volta para a rede como entrada no próximo passo de tempo $X_t + 1$, como ilustrado da Figura 3.1. Esse processo permite que a rede mantenha uma espécie de memória sequencial, permitindo a aprendizagem de padrões temporais em dados de sequência. No entanto, as RNN possuem uma limitação fundamental que é a chamada "memória de curto prazo". Isso significa que, à medida que a sequência se estende, as informações do início da sequência são gradualmente esquecidas, tornando-o menos adequado para lidar com dependências a longo prazo. Esta limitação se traduz em dificuldades para modelar relações temporais complexas e, por conseguinte, prejudica o desempenho em muitas tarefas.

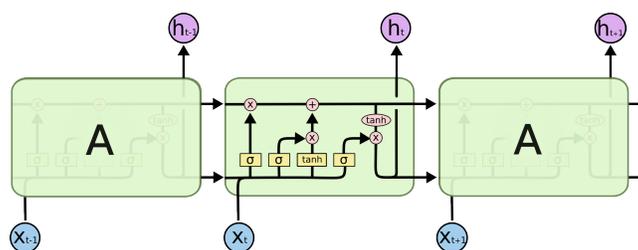
Figura 3.1 – Conexão retroativas do modelo RNN.



Como alternativa, o modelo de Redes de Longa Memória de Curto Prazo (LSTM) tem ganhado destaque na previsão de preços. Estudos, como o conduzido por (FISCHER; KRAUSS, 2018), evidenciam que o LSTM apresenta uma capacidade significativa na superação dos desafios inerentes às Redes Neurais Recorrentes (RNNs). Ao incorporar uma memória de longo prazo, o LSTM supera as limitações das RNNs em relação às dependências temporais de curto prazo,

proporcionando resultados mais robustos e eficazes em tarefas preditivas. A célula de memória do modelo desempenha um papel central ao abordar o desafio do desaparecimento do gradiente em redes neurais recorrentes. A célula possui uma memória de longo prazo, atualizada por meio de portões de esquecimento e entrada. O portão de esquecimento decide o que deve ser mantido ou esquecido da memória anterior, enquanto o portão de entrada controla as atualizações da memória. A combinação desses elementos permite que a célula capture e mantenha informações de longo prazo, essencial para tarefas envolvendo dependências temporais complexas. O portão de saída determina a saída final da célula, equilibrando a informação relevante. Essa arquitetura eficaz, ilustrada da Figura 3.2, torna os LSTMs adequados para aplicações que exigem a captura de padrões temporais em dados sequenciais. Essa abordagem representa um avanço crucial na capacidade de modelagem de sequências temporais complexas, ampliando as possibilidades de aplicação em diversos domínios. No entanto, assim como em redes profundas convencionais, as LSTMs podem sofrer com o desvanecimento do gradiente em sequências muito longas.

Figura 3.2 – Estrutura do modelo LSTM.



O desafio com redes profundas convencionais é a dificuldade de treinar à medida que a rede cresce em profundidade. À medida que a informação passa por várias camadas, ela pode ser diluída ou perdida, resultando em um fenômeno conhecido como "desvanecimento do gradiente" (YU, 2018). As Redes Neurais Residuais (ResNets) são uma arquitetura avançada de redes neurais profundas que

introduzem a ideia de blocos residuais que abordam esse problema incorporando blocos residuais, que contêm conexões diretas que "pulam" camadas.

Introduzir blocos residuais em uma arquitetura LSTM ajuda a mitigar o desvanecimento do gradiente ao permitir que a informação da sequência original flua sem impedimentos (KIM; EL-KHAMY; LEE, 2017). Essa abordagem é particularmente valiosa em tarefas que envolvem sequências temporais extensas, como previsão de séries temporais, processamento de linguagem natural e outras aplicações onde a captura de dependências temporais de longo prazo é crucial.

4 METODOLOGIA

Neste capítulo, são apresentadas as técnicas e processos empregados na modelagem dos dados, na seleção de variáveis de entrada, nos modelos de previsão testados, assim como nas técnicas de treinamento e validação. É crucial ressaltar que este projeto foi subdividido em três partes distintas: um modelo de previsão utilizando exclusivamente a curva de preço da tela atual e futuras, um modelo empregando apenas os dados de S&D, e outro modelo integrando todas as variáveis de forma conjunta.

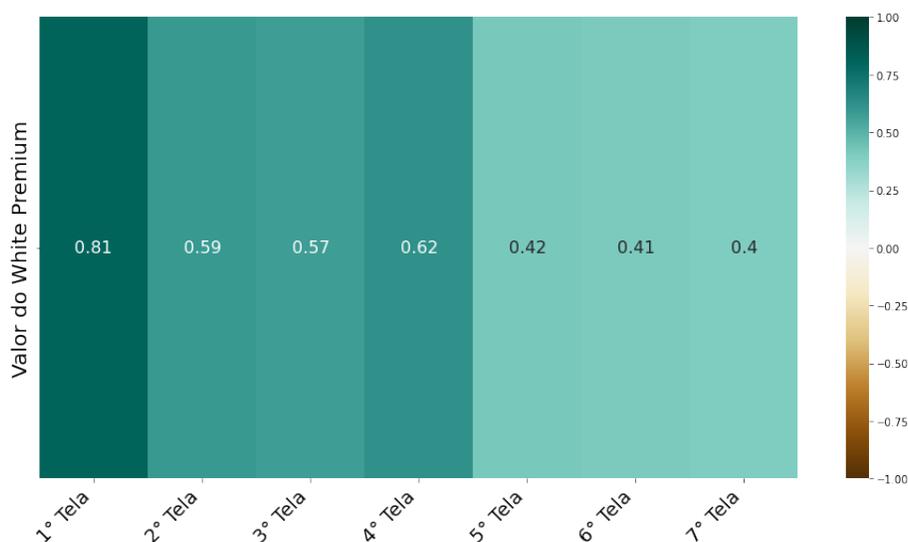
4.1 Modelagem dos Dados de Preço

Conforme mencionado, o propósito deste documento consiste em prever a diferença entre os preços dos contratos de açúcar negociados nas bolsas de Nova York e Londres, empregando modelos de aprendizado de máquina. Para isso, utilizou-se uma base de dados contendo os preços diários de NY#11 e LDS, assim como os preços negociados nas próximas telas no mesmo período. A fim de calcular o *white premium*, realizou-se apenas a diferença dos preços do açúcar da bolsa de Londres pelos de Nova York.

4.1.1 Correlação Entre o Preço do White Premium e Futuras Telas

Os preços mensais do *white premium* e das próximas sete futuras telas foram segregados em uma janela de dados. Isso possibilitou calcular o coeficiente de Pearson e plotar o resultado utilizando as bibliotecas *pandas* e *matplotlib* do Python. A Figura 4.1 ilustra os valores de *r* encontrados para cada tela.

As futuras telas apresentam uma forte correlação com o preço do *white premium*, especialmente as telas mais próximas. Esse resultado sustenta a hipótese de que pode-se prever o preço do açúcar apenas as utilizando.

Figura 4.1 – Correlação entre o *white premium* e futuras telas.

4.1.2 Correlações entre o White Premium e os Dados de S&D

Sabendo que, as bases de dados de S&D são frequentemente incertas, sendo algumas variáveis desafiadoras de se mensurar, como a produção de cada tipo de açúcar de todos os países, em muitos casos, os dados globais são deduzidos e aproximados por categorias. A fim de testar essa hipótese e compreender a melhor granulometria para utilizar esses dados, realizou-se a correlação do *white premium* com a produção de açúcar bruto, de baixa qualidade, alta qualidade e açúcar total, apresentado nas Figura 4.2 e Figura 4.3.

Os resultados revelaram uma correlação de 0,37 entre o açúcar de baixa qualidade, -0,049 entre o açúcar de alta qualidade, 0,22 entre o açúcar bruto e 0,31 entre o açúcar de baixa qualidade. O que parece ser uma coincidência, uma vez que o valor do *white premium* é calculado a partir dos preços do açúcar bruto e de alta qualidade negociados em bolsa, o açúcar de baixa qualidade não é comercializado nas bolsas de Nova York e Londres. Contudo, suspeitou-se que essa correlação era pelo acaso e não tinha causalidade sobre a variável *white premium*, para avaliar

Figura 4.2 – Correlação entre o *white premium* e os dados de produção de açúcar total e alta qualidade.

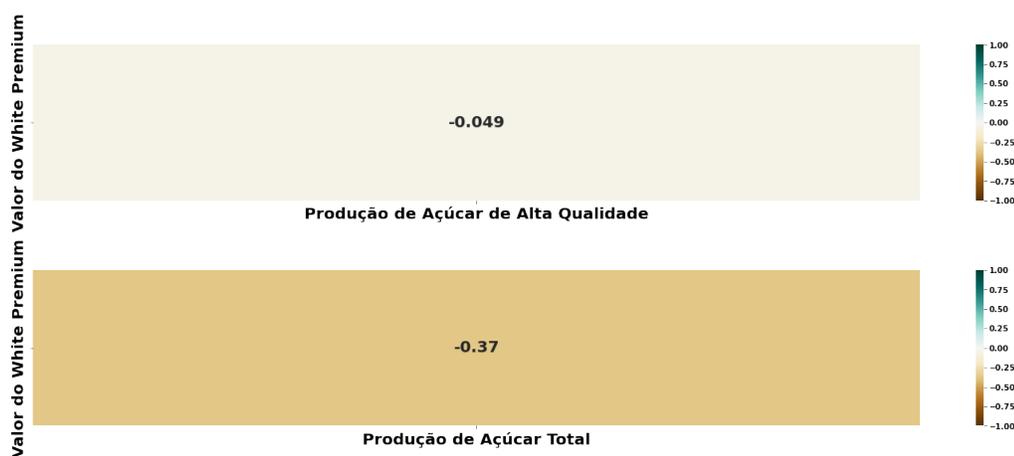
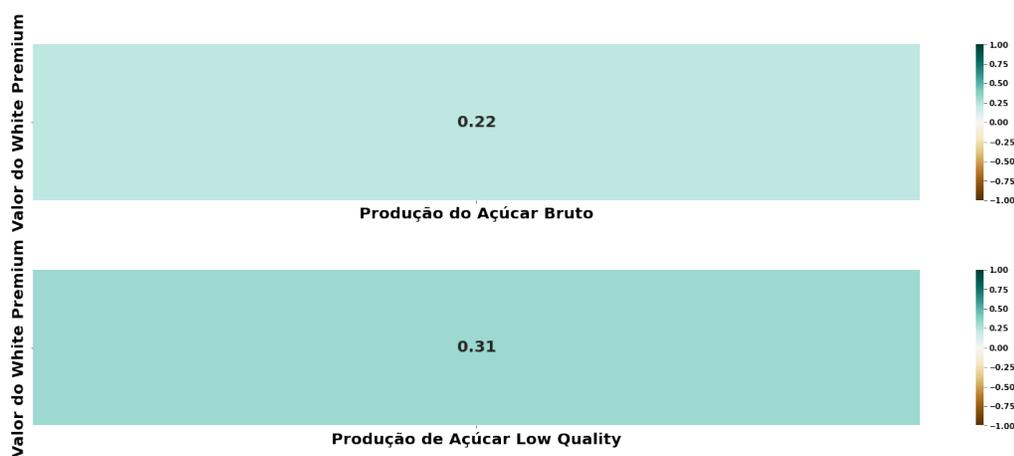


Figura 4.3 – Correlação entre o *white premium* e os dados de produção de açúcar bruto e baixa qualidade.



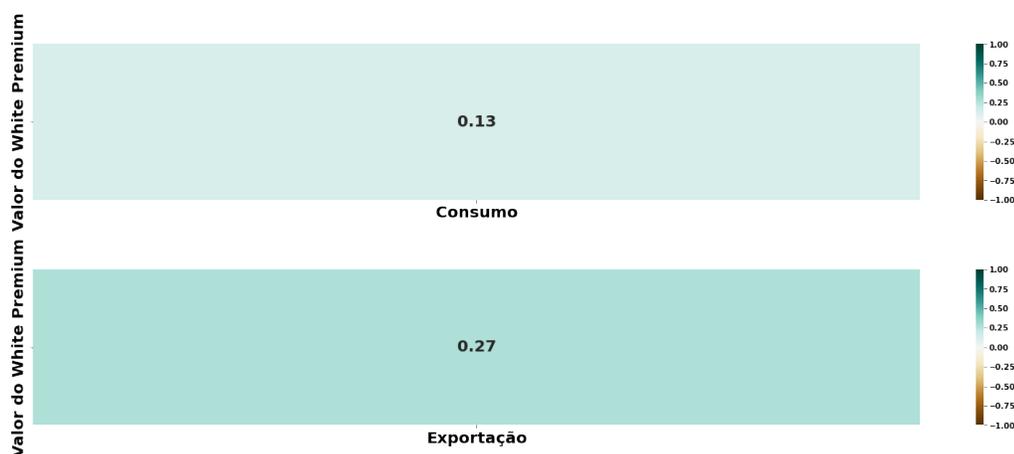
isso utilizou-se o teste de causalidade de Granger, cujo resultado é ilustrado na Tabela 4.1.

Como previsto, a variável que representa o açúcar total apresenta correlação e causalidade, ao contrário da variável que representa o açúcar de baixa qualidade. Isso evidencia que trabalhar com os dados de S&D em uma granularidade alta pode introduzir ruído ao modelo, razão pela qual optou-se por utilizar os dados de produção apenas em escala global.

Tabela 4.1 – Teste de causalidade de granger com dados de produção.

Teste	Valor- <i>p</i>	Resultado
Açúcar de Baixa Qualidade	0,2062	Não indica causalidade
Açúcar Global	0,0182	Indica causalidade

Além dos dados de produção, a base de S&D apresenta informações sobre importação, exportação, consumo e estoque. Testou-se a correlação e causalidade de cada uma dessas variáveis para compreender se alguma delas, isoladamente, exerce significativa influência na curva de preço do White Premium. As Figuras 4.4, 4.5 e a Tabela 4.2 ilustram os resultados encontrados.

Figura 4.4 – Correlação entre o *white premium* e os dados de consumo e exportação.

Todas as variáveis demonstraram não possuir uma correlação forte com a variável prevista. No entanto, apenas o estoque e a importação foram aprovados no teste de Granger, indicando ter causalidade. Considerando o comércio global de açúcar, centrado em países que produzem bruto ou alta qualidade para exportação, países que importam bruto para refinar e exportar alta qualidade, e países importadores de alta qualidade, optou-se por concentrar a análise nos países mais relevantes. O valor dos contratos de açúcar no NY#11 está diretamente ligado à oferta de açúcar bruto, influenciando os valores dos contratos e, por conseguinte, o preço do *white premium*. O mesmo se aplica à importação de alta qualidade, onde

Figura 4.5 – Correlação entre o *white premium* e os dados de importação e estoque.

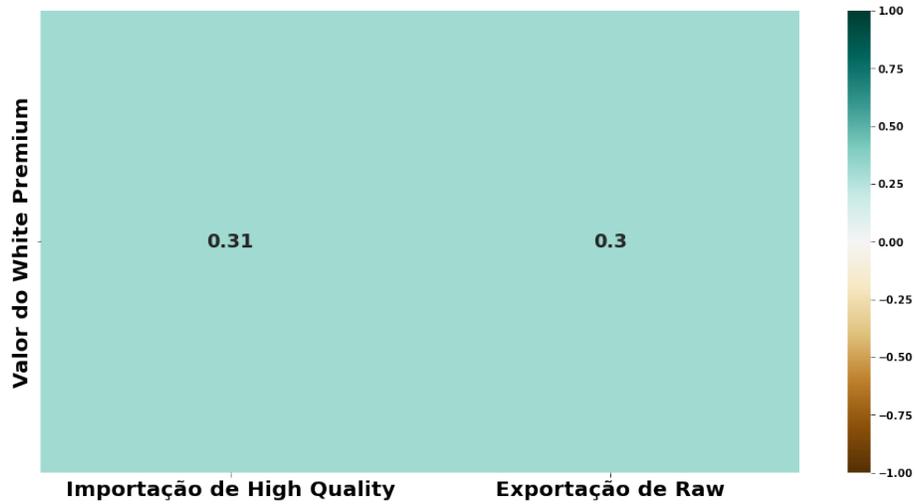
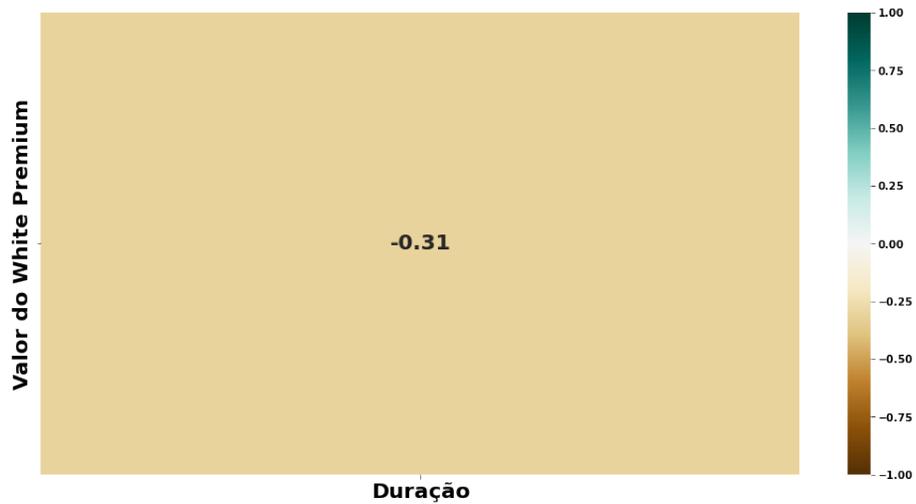
Tabela 4.2 – Teste de causalidade de granger com dados de S&D.

Teste	Valor- <i>p</i>	Resultado
Consumo	0,4466	Não indica causalidade
Exportação	0,3014	Não indica causalidade
Importação	0,0258	Indica causalidade
Estoque	0,0229	Indica causalidade

a demanda impacta diretamente no preço do açúcar na bolsa de Londres. Dessa forma, filtrou-se os dados de exportação e importação, identificando os 15 países com maior influência e calculando a correlação com a curva de preços do White Premium, segundo a figura 4.6 ilustra os resultados obtidos.

Os resultados revelam uma melhor correlação entre os dados de importação e exportação. Resta apenas analisar o consumo de açúcar, uma variável desafiadora de correlacionar isoladamente. No entanto, quando combinada com outras informações, é possível utilizá-lo para calcular o tempo de duração do estoque dos países que mais importam açúcar de alta qualidade. A correlação resultante pode ser visualizada na Figura 4.7.

Após essas análises mais aprofundadas, foi possível demonstrar como a influência dos dados de S&D teorizados se refletem nos testes de correlação e causalidade, apesar de não indicarem correlações fortes, ainda podem ser variáveis

Figura 4.6 – Correlação entre o *white premium* e os dados de importação e exportação.Figura 4.7 – Correlação entre o *white premium* e a duração dos estoque.

que o modelos de machine learning pode utilizar para prever o preço do *white premium*.

4.2 Modelo de Rede Neural

Neste trabalho, foram empregadas duas arquiteturas distintas, LSTM e LSTM Residual, para antecipar as variações nos preços do açúcar entre as bolsas de Nova York e Londres. Ambos os modelos foram desenvolvidos e implementados em Python, utilizando a biblioteca TensorFlow e seguindo as diretrizes do tutorial de séries temporais fornecido pelo (ABADI et al., 2015).

O primeiro modelo, um LSTM convencional, é estruturado como uma rede sequencial. A camada LSTM, com 32 unidades, é projetada para processar sequências temporais. A rede neural foi configurada para que em vez de produzir apenas a última saída da sequência, a camada LSTM retorna uma sequência completa de saídas para cada passo temporal. Isso significa que a rede é capaz de aprender e considerar informações ao longo de toda a sequência temporal durante o treinamento.

Por outro lado, o segundo modelo, LSTM Residual, adota uma abordagem mais complexa. Este modelo, incorpora a saída do modelo ao longo do tempo. Cada previsão para um determinado passo temporal é influenciada não apenas pela entrada correspondente, mas também pela soma acumulada dos deltas previstos ao longo da sequência temporal. Isso proporciona ao modelo a capacidade de aprender padrões temporais mais intrincados e capturar nuances nas flutuações dos preços do açúcar entre as bolsas estudadas.

Ambos os modelos foram treinados e ajustados aos dados temporais, utilizando conjuntos de treinamento, validação e teste, ao longo de um número máximo de épocas definido em 50, número escolhido após verificar que épocas acima de 50 não indicavam melhorias no desempenho e causava *overfitting*. Essa abordagem metodológica visa aprimorar a capacidade preditiva dos modelos em relação às variações nas séries temporais de preços do açúcar.

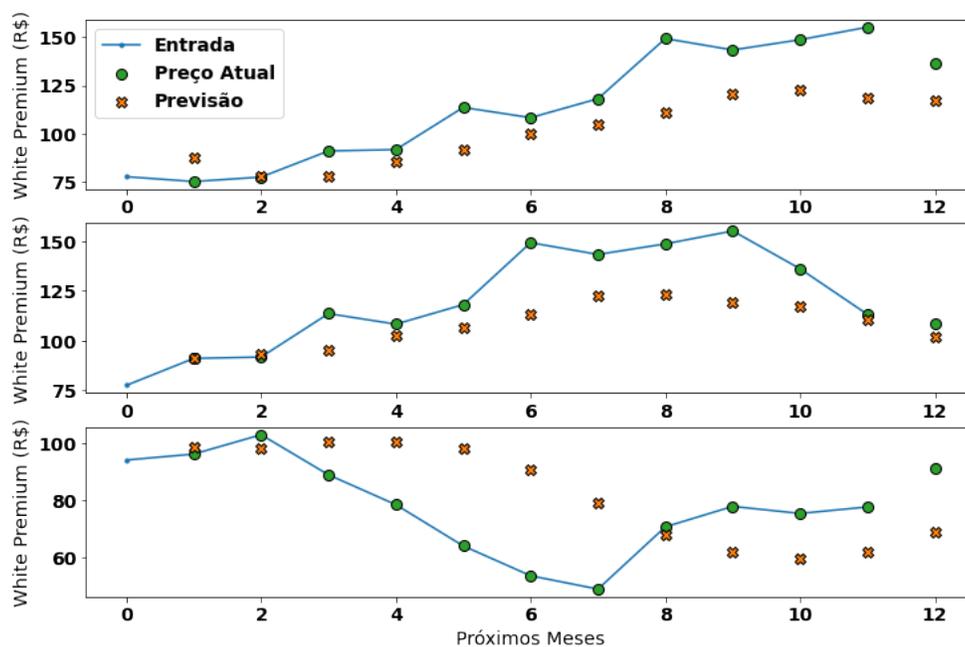
5 RESULTADOS

Neste capítulo, serão apresentados os resultados obtidos ao treinar os modelos propostos, assim como a influência dos dados apresentados anteriormente e o melhor modelo encontrado.

5.1 Modelos Treinados com Dados de S&D

Conforme apresentado na Seção 1.1, a escolha da rede de Longa Memória de Curto Prazo (LSTM) como primeiro modelo de previsão decorre da ampla utilização desse modelo em séries temporais. A Figura 5.1 e a Tabela 5.1 ilustram os resultados derivados exclusivamente dos dados de oferta e demanda (S&D) e histórico de preço.

Figura 5.1 – Previsões realizadas com o modelo LSTM treinado com dados de S&D e histórico de preço.



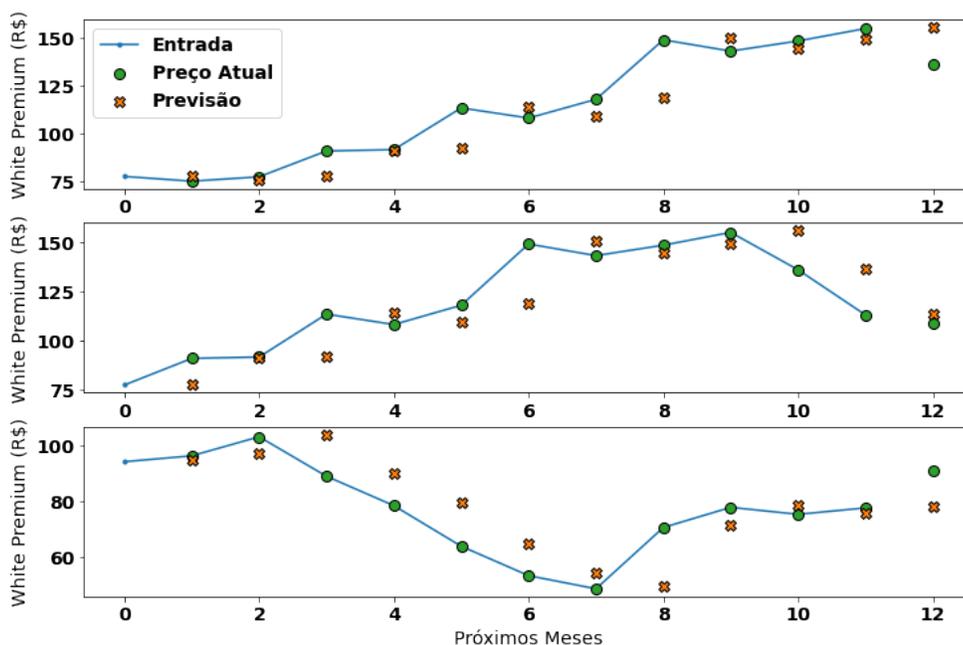
Observa-se que o modelo LSTM demonstrou adaptação eficaz à curva de preço do açúcar, revelando erros inferiores a 1% em alguns pontos. No entanto, em

Tabela 5.1 – Resultados dos testes com o modelo LSTM treinado com dados de S&D e histórico de preço.

Teste	Erro Percentual Médio (%)
1	9,22
2	14,84
3	27,57

situações em que a curva não exibe uma característica constante, o desempenho do modelo não correspondeu às expectativas. Essa limitação é uma das questões que o modelo de LSTM Residual visa abordar. A Figura 5.2 e Tabela 5.2 ilustram os resultados do modelo LSTM Residual.

Figura 5.2 – Previsões realizadas com o modelo LSTM Residual treinado com dados de s&d e histórico de preço.



Conforme antecipado, o modelo LSTM Residual demonstrou um desempenho superior ao LSTM, adaptando-se de maneira mais eficiente ao cenário representado no terceiro gráfico. Nos gráficos mencionados anteriormente, o modelo apresentou um erro percentual médio de 9%, 8% e 13%, indicando sua viabilidade

Tabela 5.2 – Resultados dos testes com o modelo LSTM Residual treinado com dados de S&D e histórico de preço.

Teste	Erro Percentual Médio (%)
1	9,49
2	10,04
3	13,72

para oferecer suporte nas tomadas de decisão nas empresas do setor açucareiro. No entanto, o modelo ainda evidencia certa dificuldade em lidar com mudanças abruptas nos valores, como exemplificado no sexto mês do primeiro gráfico da Figura 5.2.

5.2 Modelos Treinados com os Preços de Futuras Telas

Para uma análise comparativa, os modelos foram treinados exclusivamente com base no histórico de preços e nas futuras telas, visando identificar possíveis reduções nos erros médios e avaliar a adaptabilidade em meses caracterizados por mudanças abruptas nos preços. Os resultados dessa abordagem são apresentados nas Figuras 5.3 e 5.4 e detalhados nas Tabelas 5.3 e 5.4.

Apesar da modificação nos dados de entrada, os resultados permaneceram bastante similares. O modelo LSTM continuou a apresentar dificuldade em prever curvas que não possuem uma característica constante. Assim como o modelo LSTM Residual resolveu efetivamente esse desafio, alcançando erros médios próximos de 10% com o modelo treinado com dados de oferta e demanda.

5.3 Melhor Modelo

O modelo LSTM Residual demonstra melhor desempenho, embora, em ambos os casos, os erros observados tenham sido comparáveis, como ilustrado na Tabela 5.5. Esse padrão sugere que os dados de S&D e Futuras Telas não exercem uma influência significativa, e o modelo prevê o preço do White Premium quase

Figura 5.3 – Previsões realizadas com o modelo LSTM treinado com dados de futuras telas e histórico de preço.

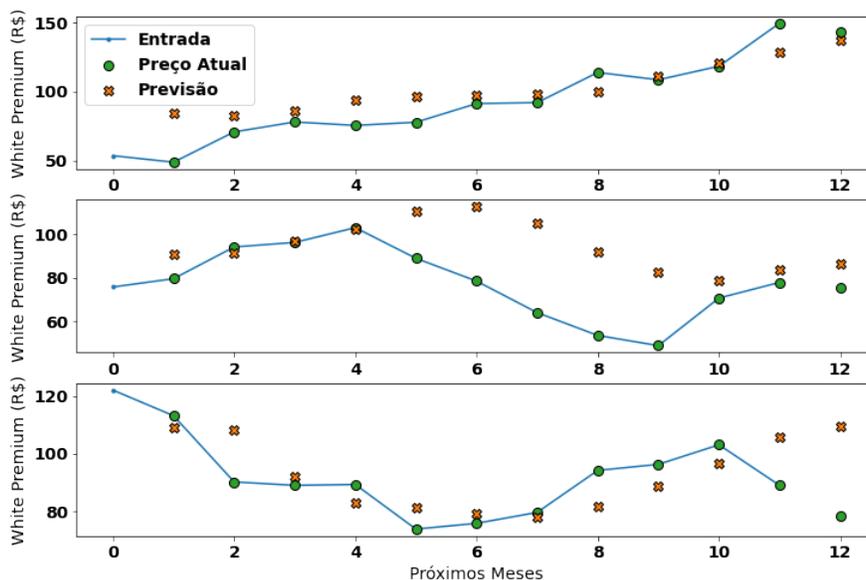


Tabela 5.3 – Resultados dos testes com o modelo LSTM treinado com dados de futuras telas e histórico de preço.

Teste	Erro Percentual Médio (%)
1	16,96
2	21,36
3	13,88

exclusivamente com base no histórico de preços. Diante disso, foram conduzidos dois testes adicionais: treinar um modelo LSTM com todos os dados disponíveis e outro com apenas os dados históricos de preço do White Premium. Os resultados estão ilustrados nas Figuras 5.5 e 5.6 e nas Tabelas 5.6 e 5.7, respectivamente.

Dessa forma, evidencia-se que, para o modelo LSTM, apenas a curva de preço é suficiente para prever o preço do White Premium, com erros médios próximos a 10%. Embora outros dados apresentem correlações com o preço do açúcar, essas correlações se revelaram tênues, mais prejudicando do que contribuindo para o modelo.

Figura 5.4 – Previsões realizadas com o modelo LSTM Residual treinado com dados de futuras telas e histórico de preço.

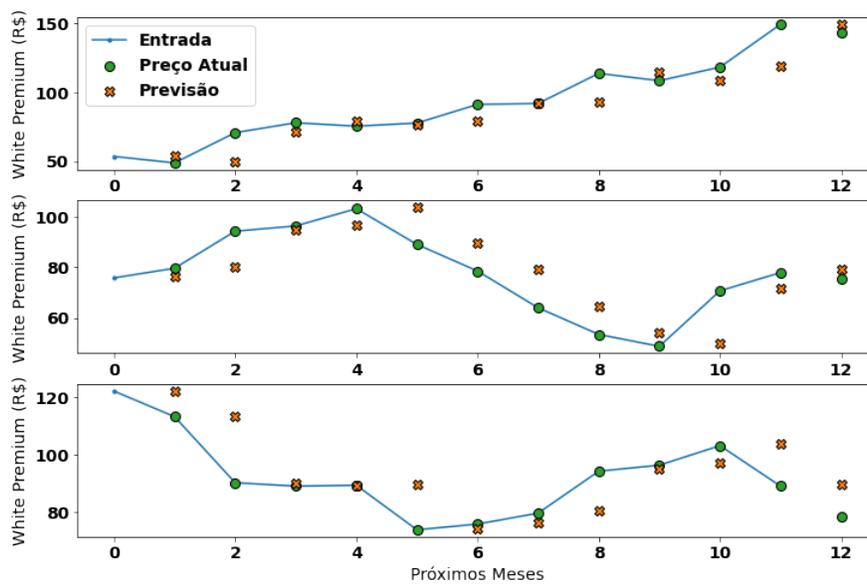


Tabela 5.4 – Resultados dos testes com o modelo LSTM Residual treinado com dados de futuras telas e histórico de preço.

Teste	Erro Percentual Médio (%)
1	9,97
2	13,85
3	12,02

Tabela 5.5 – Delta entre os erros percentuais médios do modelo com todos os dados e o modelo com apenas o histórico de preço do *white premium*.

Teste	Delta do Erro Percentual Médio (%)
1	0,48
2	1,98
3	0,13

Figura 5.5 – Previsões realizadas com o modelo LSTM Residual treinado com todos os dados.

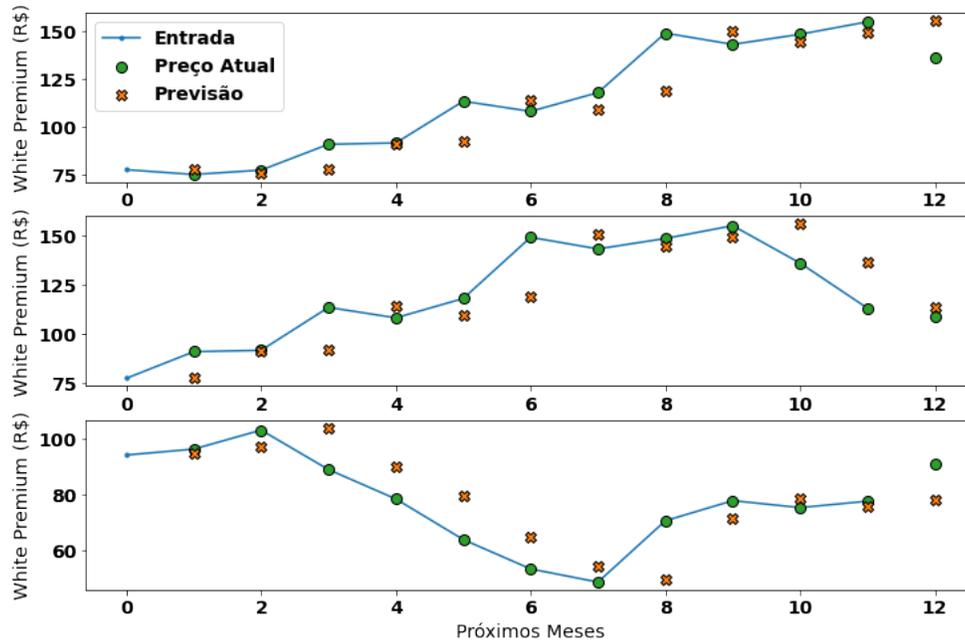


Tabela 5.6 – Resultados dos testes com o modelo LSTM Residual treinado com todos os dados.

Teste	Erro Percentual Médio (%)
1	13,67
2	12,70
3	9,42

Figura 5.6 – Previsões realizadas com o modelo LSTM Residual treinado apenas com dados históricos de preço.

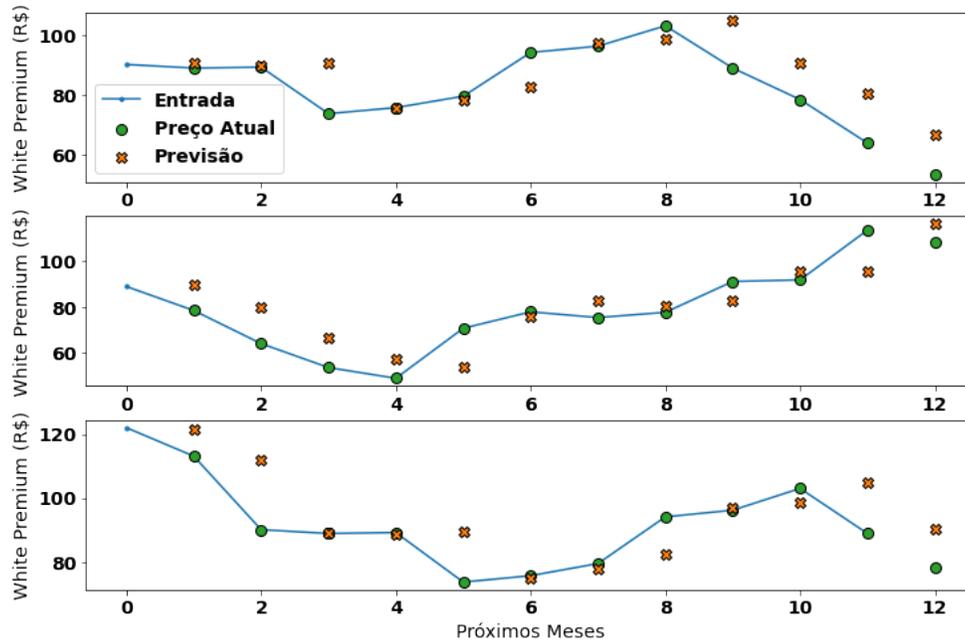


Tabela 5.7 – Resultados dos testes com o modelo LSTM Residual treinado apenas com dados históricos de preço.

Teste	Erro Percentual Médio (%)
1	12,77
2	8,12
3	9,24

6 CONCLUSÃO

Este trabalho apresenta uma aplicação voltada para a estimativa da diferença entre os preços do açúcar negociados nas bolsas de Nova York e Londres, utilizando técnicas de aprendizado profundo de máquinas. Além disso, o desempenho de duas estruturas de redes neurais distintas (LSTM e LSTM Residual) foi avaliado, revelando que o modelo LSTM Residual se ajustou de maneira mais eficaz à curva histórica dos preços do açúcar. Adicionalmente, a pesquisa evidenciou que o histórico de preços do açúcar é suficiente para a construção de um modelo de aprendizado de máquina, resultando em erros médios próximos a 10%. Apesar da existência de correlações entre os dados de oferta e demanda (S&D) e as tendências futuras de mercado com os preços do açúcar, constatou-se que essa relação não é suficiente para aprimorar o modelo a ponto de reduzir o erro médio, podendo, em alguns casos, comprometer o desempenho e aumentar o erro.

Por fim, é importante ressaltar que, embora não tenha sido possível melhorar o desempenho dos modelos ao incorporar dados de S&D e futuras tendências, essas informações não devem ser descartadas em pesquisas futuras. Elas podem fornecer insights valiosos para modelos com estruturas diferentes daquelas testadas neste estudo, indicando a relevância de explorar abordagens alternativas para otimizar a precisão das previsões de preços do açúcar.

REFERÊNCIAS

- ABADI, M. et al. **TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems**. 2015. Software available from tensorflow.org. Disponível em: <<https://www.tensorflow.org/>>.
- AHLFELD, H. The world sugar market at a crossroads. **Zuckerindustrie. Sugar industry**, v. 135, p. 365–370, 06 2010.
- ALAMEER, Z. et al. Forecasting gold price fluctuations using improved multilayer perceptron neural network and whale optimization algorithm. **RESOURCES POLICY**, v. 61, p. 250–260, JUN 2019. ISSN 0301-4207.
- AMEUR, H. B.; BOUBAKER, S.; FTITI, Z. Forecasting commodity prices: empirical evidence using deep learning tools. **Ann Oper Res**, jan. 2023. Disponível em: <<https://doi.org/10.1007/s10479-022-05076-6>>.
- BABUNĚK, O. Comparison of impact of selected aspects on supply, demand and price of sugar in developing and developed countries, in the world and in oecd and eu countries. **Listy Cukrovarnicke a Reparske**, v. 132, p. 190–195, 01 2016.
- BOHL, M. T.; STEFAN, M. Return dynamics during periods of high speculation in a thinly traded commodity market. **Journal of Futures Markets**, Wiley Online Library, v. 40, n. 1, p. 145–159, 2020.
- BOHMANN, M. J.; MICHAYLUK, D.; PATEL, V. Price discovery in commodity derivatives: Speculation or hedging? **Journal of Futures Markets**, Wiley Online Library, v. 39, n. 9, p. 1107–1121, 2019.
- CERMAK, P. The global trade of sugar. **Listy Cukrovarnické a Řepářské**, v. 125, p. 302–305, 11 2009.
- ETHINGTON, C. A.; THOMAS, S. L.; PIKE, G. R. Back to the basics: Regression as it should be. In: _____. **Higher Education: Handbook of Theory and Research**. Dordrecht: Springer Netherlands, 2002. p. 263–293. ISBN 978-94-010-0245-5. Disponível em: <https://doi.org/10.1007/978-94-010-0245-5_6>.
- FISCHER, T.; KRAUSS, C. Deep learning with long short-term memory networks for financial market predictions. **European Journal of Operational Research**, v. 270, n. 2, p. 654–669, 2018. ISSN 0377-2217. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0377221717310652>>.
- GRANGER, C. Testing for causality: A personal viewpoint. **Journal of Economic Dynamics and Control**, v. 2, p. 329–352, 1980. ISSN 0165-1889. Disponível em: <<https://www.sciencedirect.com/science/article/pii/016518898090069X>>.

GRAVES, A. Long short-term memory. In: _____. **Supervised Sequence Labelling with Recurrent Neural Networks**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. p. 37–45. ISBN 978-3-642-24797-2. Disponível em: <https://doi.org/10.1007/978-3-642-24797-2_4>.

GUNAWAN, R.; KHODRA, M. L.; HARLILI. Commodity price prediction using neural network case study: Crude palm oil price. In: SADIKIN, R.; SUBEKTI, A. (Ed.). **2013 INTERNATIONAL CONFERENCE ON COMPUTER, CONTROL, INFORMATICS AND ITS APPLICATIONS (IC3INA)**. [S.l.], 2013. p. 243–248. ISBN 978-1-4799-1078-6. 2013 International Conference on Computer, Control, Informatics and Its Applications (IC3INA), Indonesian Inst Sci, Res Ctr Informat, Jakarta, INDONESIA, NOV 19-20, 2013.

HIRSHLEIFER, D. Hedging pressure and futures price movements in a general equilibrium model. **Econometrica: Journal of the Econometric Society**, JSTOR, p. 411–428, 1990.

HIRSHLEIFER, D. Residual Risk, Trading Costs, and Commodity Futures Risk Premia. **The Review of Financial Studies**, v. 1, n. 2, p. 173–193, 03 2015. ISSN 0893-9454. Disponível em: <<https://doi.org/10.1093/rfs/1.2.173>>.

HOCHREITER, S.; SCHMIDHUBER, J. Long Short-Term Memory. **Neural Computation**, v. 9, n. 8, p. 1735–1780, 11 1997. ISSN 0899-7667. Disponível em: <<https://doi.org/10.1162/neco.1997.9.8.1735>>.

KIM, J.; EL-KHAMY, M.; LEE, J. Residual lstm: Design of a deep recurrent architecture for distant speech recognition. In: INT SPEECH COMMUN ASSOC; STOCKHOLM UNIV; KTH ROYAL INST TECHNOL; KAROLINSKA INST; AMAZON ALEXA; DIDI; FURHAT ROBOT; MICROSOFT; EZ ALIBABA GRP; CIRRUS LOGIC; CVTE; GOOGLE; BAIDU; IBM RES; YAHOO JAPAN; NUANCE; VOICE PROVIDER; ASM SOLUT LTD; MITSUBISHI ELECT RES LAB; YANDEX. **18TH ANNUAL CONFERENCE OF THE INTERNATIONAL SPEECH COMMUNICATION ASSOCIATION (INTERSPEECH 2017), VOLS 1-6: SITUATED INTERACTION**. [S.l.], 2017. (Interspeech), p. 1591–1595. ISBN 978-1-5108-4876-4. ISSN 2308-457X. 18th Annual Conference of the International-Speech-Communication-Association (INTERSPEECH 2017), Stockholm, SWEDEN, AUG 20-24, 2017.

MAITAH, M.; SMUTKA, L. The development of world sugar prices. **Sugar Tech**, v. 21, 04 2018.

MINTZ, S. W. **Sweetness and Power : The Place of Sugar in Modern History**. York N.Y: Viking: [s.n.], 1985.

PARANHOS, R. et al. Desvendando os mistérios do coeficiente de correlação de pearson: o retorno. **Leviathan (São Paulo)**, n. 8, p. 66–95, ago. 2014. Disponível em: <<https://www.revistas.usp.br/leviathan/article/view/132346>>.

REGINA, G. **Brasil exporta volume estável de açúcar em 2022, mas preços sobem 19,6[S.I.], 2023.** Disponível em: <<https://www.novacana.com/noticias/brasil-exporta-volume-estavel-acucar-2022-precos-sobem-19-6-120123>>.

SCHMIEG, E. Factors influencing price developments of commodities. **Econstor**, 1993. Disponível em: <<https://www.econstor.eu/bitstream/10419/140401/1/v28-i03-a07-BF02928118.pdf>>.

SCHWARCZ LILIA MORITZ E STARLING, H. M. M. **Brasil: uma biografia.** São Paulo: Companhia das Letras, 2015.

SHOJAIE, A.; FOX, E. B. Granger causality: A review and recent advances. **Annual Review of Statistics and Its Application**, v. 9, n. 1, p. 289–319, 2022. Disponível em: <<https://doi.org/10.1146/annurev-statistics-040120-010930>>.

STANTON, J. M. Galton, pearson, and the peas: A brief history of linear regression for statistics instructors. **Journal of Statistics Education**, Taylor Francis, v. 9, n. 3, 2001. Disponível em: <<https://doi.org/10.1080/10691898.2001.11910537>>.

TODD, M. High world prices: Is asia's production cycle to blame? **Zuckerindustrie**, 2010.

UNICA. **Balço de Atividades 2012/13 a 2018/19.** [S.l.], 2019. Disponível em: <<https://unica.com.br/wp-content/uploads/2019/06/Relatorio-Atividades-201213-a-201819.pdf>>.

WANG, J.; LI, X. A combined neural network model for commodity price forecasting with ssa. **SOFT COMPUTING**, v. 22, n. 16, SI, p. 5323–5333, AUG 2018. ISSN 1432-7643.

YU, S. Residual learning and lstm networks for wearable human activity recognition problem. In: CHEN, X.; ZHAO, Q. (Ed.). **2018 37TH CHINESE CONTROL CONFERENCE (CCC)**. [S.l.], 2018. (Chinese Control Conference), p. 9440–9447. ISBN 978-9-8815-6395-8. ISSN 2161-2927. 37th Chinese Control Conference (CCC), Wuhan, PEOPLES R CHINA, JUL 25-27, 2018.

YULE, G. U. Henry Ludwell Moore, Forecasting the Yield and the Price of Cotton. **The Economic Journal**, v. 28, n. 110, p. 216–218, 06 1918. ISSN 0013-0133. Disponível em: <<https://doi.org/10.2307/2221874>>.