



**FUNDAÇÃO UNIVERSIDADE FEDERAL DO ABC
CENTRO DE ENGENHARIA, MODELAGEM E CIÊNCIAS SOCIAIS
APLICADAS**

GABRIEL ARAUJO GRACIA

**PREVISÃO DE PREÇOS DE COMMODITIES UTILIZANDO
APRENDIZADO DE MÁQUINA**

**Santo André, São Paulo
2023**

GABRIEL ARAUJO GRACIA

PREVISÃO DE PREÇOS DE COMMODITIES UTILIZANDO
APRENDIZADO DE MÁQUINA

Trabalho de Conclusão de Curso
apresentado à Universidade Federal
do ABC como requisito parcial para a
obtenção do título de Bacharel em
Engenharia da Informação.

Orientador: Prof. Dr. Ricardo Suyama

Santo André, São Paulo
2023

RESUMO

Na busca constante por modelos preditivos eficazes e precisos para análise de séries temporais, a presente pesquisa visa explorar e contrapor três métodos predominantes: ARIMA, SARIMA e redes LSTM. O ARIMA, consolidado na estatística clássica, e seu descendente SARIMA, que adiciona uma camada de complexidade para capturar efeitos sazonais, são discutidos em profundidade. Paralelamente, redes LSTM, derivadas da aprendizagem profunda, são destacadas por sua habilidade superior em aprender dependências de longo prazo e padrões complexos. Através da implementação em Python, uma linguagem de programação altamente favorável para análises detalhadas, este estudo busca avaliar e comparar a eficácia desses modelos na previsão dos preços das commodities: soja, minério de ferro e café, guiado por métricas de erro apropriadas para garantir a precisão das previsões. Este trabalho tem como objetivo guiar futuros pesquisadores e profissionais na escolha consciente do modelo mais adequado para análises de séries temporais.

Palavras-chave: ARIMA, SARIMA, LSTM, Séries Temporais.

ABSTRACT

In the relentless pursuit of effective and accurate predictive models for time series analysis, the present research aims to explore and contrast three predominant methods: ARIMA, SARIMA, and LSTM networks. The ARIMA, rooted in classic statistics, and its offspring SARIMA, which adds a layer of complexity to capture seasonal effects, are discussed in depth. Parallely, LSTM networks, stemming from deep learning, are highlighted for their superior ability to learn long-term dependencies and complex patterns. Through implementation in Python, a highly favorable programming language for detailed analyses, this study seeks to assess and compare the effectiveness of these models in forecasting the prices of commodities: soy, iron ore, and coffee, guided by appropriate error metrics to ensure the accuracy of predictions. This work aspires to guide future researchers and practitioners in the conscious choice of the most suitable model for time series analyses.

Keywords: ARIMA, SARIMA, LSTM, Time Series.

SUMÁRIO

1. INTRODUÇÃO.....	1
2. OBJETIVOS.....	3
3. EMBASAMENTO TEÓRICO	
3.1. ARIMA.....	4
3.2. SARIMA.....	7
3.3. LSTM.....	9
4. METODOLOGIA	
4.1. EXTRAÇÃO DE DADOS E FERRAMENTAS.....	14
4.2. ENTRADA E DEFINIÇÕES INICIAIS.....	16
4.3. MODELOS.....	17
5. RESULTADOS E DISCUSSÃO.....	19
6. CONCLUSÃO.....	28
7. REFERÊNCIAS.....	29
8. APÊNDICE A.....	30
9. APÊNDICE B.....	54
10. APÊNDICE C.....	59
11. APÊNDICE D.....	62

1. INTRODUÇÃO

A análise e previsão de séries temporais têm-se mantido como um campo robusto e essencial em diversos domínios, incluindo economia, finanças, meteorologia, entre outros. Modelos de previsão desempenham um papel crucial na tomada de decisões bem-informadas, fundamentando estratégias e políticas^[1].


Entre os modelos disponíveis, *Autoregressive Integrated Moving Average*^{[1][2]} (ARIMA), *Seasonal Autoregressive Integrated Moving Average*^{[1][2]} (SARIMA) e *Long-Short Term Memory*^[3] (LSTM) destacam-se cada um com suas especificidades, forças e limitações. O ARIMA e o SARIMA têm sido tradicionalmente aplicados devido à sua capacidade de compreender e prever séries temporais lineares com precisão, capturando padrões e sazonalidades presentes nos dados. Por outro lado, as redes LSTM são capacitadas para analisar séries temporais de maior complexidade, acomodando uma ampla gama de padrões que podem variar significativamente ao longo do tempo.

A escolha dos preços de soja, minério de ferro e café como foco desta análise não é aleatória. Essas commodities possuem suma relevância econômica no cenário global, atuando como indicadores vitais^[4] e indispensáveis para o desenvolvimento^[5]. A soja e o café são produtos agrícolas de grande importância para a economia brasileira e mundial^[4], enquanto o minério de ferro é uma matéria-prima fundamental para a indústria siderúrgica^[5], tendo um papel crucial na economia moderna. A análise dessas commodities permite não apenas uma avaliação prática da eficácia dos modelos escolhidos, mas também oferece *insights* importantes para stakeholders neste mercado.

Outro critério de escolha é devido à importância que possuem para as exportações brasileiras. Segundo o *The Observatory for Economic Complexity*^[6] (OEC), de 2015 a 2021, as exportações brasileiras desses produtos combinados apresentaram crescimento médio de 16% ao ano,

alcançando US\$91 bilhões em 2021, sendo o país o segundo maior exportador do mundo, como mostrado na figura 1.

Figura 1 – Volume financeiro de exportações de soja, minério de ferro e café, por país exportador, em dólares americanos, de 2015 a 2021



Fonte: *The Observatory for Economic Complexity - Which countries export Soybeans, Iron Ore, and Coffee? (2015-2021)*

Com esta pesquisa, busca-se explorar e contrastar as capacidades destes três modelos proeminentes no contexto de previsões de preços destas commodities essenciais. A abordagem se dá levando em consideração as particularidades de cada modelo, buscando os melhores ajustes e interpretando seus desempenhos através de métricas de erro.

Ao avançar, este trabalho visa ilustrar suas implementações práticas através de Python, uma linguagem de programação de alto nível, e examinando seu desempenho na previsão dos preços de soja, minério de ferro e café.

Espera-se que este estudo pavimente o caminho para previsões de séries temporais mais precisas e informadas, facilitando a escolha consciente do modelo mais adequado para uma determinada aplicação, levando em consideração as características intrínsecas dos dados e as peculiaridades de cada método de previsão.

2. OBJETIVOS

Realizar a análise dos modelos ARIMA, SARIMA e LSTM no contexto de séries temporais, empregando-os na previsão de variações de preços das commodities soja, minério de ferro e café. Além de identificar qual dos modelos é capaz de fornecer as previsões mais precisas e confiáveis, este estudo visa explorar cada um dos modelos, compreendendo suas bases teóricas, as particularidades matemáticas e estatísticas que os fundamentam, bem como suas limitações.

Além disso, pretende-se criar um guia robusto que possa servir como referência para acadêmicos, pesquisadores e profissionais do mercado financeiro, elucidando os processos de implementação de cada modelo, desde a escolha e tratamento dos dados até a análise e interpretação dos resultados.

O estudo abordará o desenvolvimento e a aplicação dos modelos para a previsão de preços de commodities essenciais, com embasamento em literatura especializada, exposição dos cálculos matemáticos e algoritmos de programação. Através do uso da linguagem de programação Python, com o auxílio de visualizações gráficas, o trabalho buscará simplificar a complexidade dos modelos, esclarecer os procedimentos e os resultados obtidos.

3. EMBASAMENTO TEÓRICO

3.1 Modelo ARIMA

O modelo ARIMA, que é a sigla para *Autoregressive Integrated Moving Average*, é uma classe popular de modelos usados para prever séries temporais. Este modelo combina três componentes principais: modelos autorregressivos (AR), modelos de média móvel (MA) e um termo de integração (I)^[1].

A equação geral do modelo ARIMA pode ser expressa por:

$$(1 - \Phi(B)) * (1 - B)^d * X_t = c + (1 + \Theta(B)) * \epsilon_t$$

Em que:

- $\Phi(B)$ é o polinômio autorregressivo (AR) aplicando a defasagem B , também conhecido como operador de deslocamento;
- $(1-B)^d X_t$ é o polinômio de integração (I);
- $\Theta(B)$ é o polinômio de médias móveis (MA) aplicando a defasagem B ;
- c é a constante, que pode ser definida a partir testes de significância (estabelecimento de hipótese nula e alternativa, cálculo das estatísticas t , valor-p associado à estatística t e nível de significância do valor-p);
- ϵ_t é o erro no tempo t .

Os pesos dos polinômios autorregressivos e de médias móveis são ajustados para maximizar a função de verossimilhança dos dados do modelo. Isso é feito através do método de máxima verossimilhança, em que se utiliza um algoritmo de otimização, como o método de Newton-Raphson, que consiste em encontrar aproximações de raízes (ou zeros) de uma função real^[2].

Devido à sua capacidade de diferenciação (componente I) de séries não-estacionárias, o ARIMA é amplamente utilizado para séries econômicas que apresentem tendências ao longo do tempo, como previsão de preços e índices econômicos^[2]. Além disso, a ampla literatura disponível e a

flexibilidade na modelagem de padrões, o colocam a frente de outros modelos estatísticos, no quesito versatilidade. Apesar desse quesito, o modelo apresenta limitações relacionado à sensibilidade a *outliers*, pois esses dados podem distorcer significativamente os termos da média móvel no modelo, principalmente se fizerem parte do conjunto teste, usado para o aprendizado do modelo.

O componente autorregressivo (AR) envolve a modelagem da variável de interesse usando seus próprios valores defasados como preditores. A parte integrada (I) refere-se ao número de diferenças não sazonais necessárias para tornar a série estacionária, ou seja, dados cujas propriedades estatísticas, como média e variância, são constantes ao longo do tempo. Por fim, o componente de média móvel (MA) modela o erro do termo da previsão como uma combinação linear dos termos de erro passados.

Como o ARIMA não possui componentes sazonais, tendo seus parâmetros estáveis ao longo do tempo, é importante que utilize séries estacionárias, com média e variância consistentes ao longo do tempo, necessitando de métodos de diferenciação.

Em busca dos melhores parâmetros para o modelo, pode-se usar o *grid search*, que consiste em um loop que experimenta diversas combinações de hiperparâmetros em busca das melhores métricas.

A generalização do modelo ARIMA é expressa como ARIMA(p, d, q), onde:

- p: é o número de *lags* (atrasos) incluídos no modelo (*lag order*).
- d: é o número de vezes que as observações são diferenciadas (*degree of differencing*).
- q: é o tamanho de uma janela de um modelo de média móvel aplicado à série temporal (*order of moving average*).

A componente autoregressiva p (AR), pode ser representada como:

$$X_t = c + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \epsilon_t$$

Em que:

- X_t é o valor da série temporal no tempo t ;
- c é o valor intercepto (ou o valor de X_t caso todas as outras variáveis sejam 0);
- ϕ são os pesos aplicados aos valores atrasados (componente autorregressivo), podendo ser estimados a partir dos métodos dos mínimos quadrados, bayesianos ou da máxima verossimilhança;
- ϵ_t é o erro entre o valor real e previsto no tempo t , comumente modelado como um ruído branco, independente e distribuídos normalmente com uma média de 0 e variância constante.

A componente de integração d (I) indica o número de diferenciações (subtração entre o valor observado e d termos antes desse valor na série) para tornar a série estacionária (com média e variância constantes ao longo do tempo (Box *et al.*, 2015)), pode ser representada pela equação:

$$Y_t = (1 - B)^d X_t$$

Em que:

- B é o indicador de defasagem da série, de forma que: $B^n X_t = X_{t-n}$
- d é a ordem da diferenciação

A componente de médias móveis q (MA), pode ser representada como:

$$X_t = \theta_0 \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q}$$

Em que:

- θ é o peso aplicado aos termos de erro defasados (*lagged*) indicando como um erro inesperado no tempo t influenciará as observações, podendo ser estimado a partir do valor máximo da função de verossimilhança, a qual mede a adequação do parâmetro ao modelo;
- ϵ_t é o erro no tempo t .

3.2 Modelo SARIMA

O modelo SARIMA (acrônimo para *Seasonal Autoregressive Integrated Moving Average*), uma extensão do ARIMA, surgiu como uma ferramenta essencial para a análise de séries temporais que exibem padrões sazonais identificáveis. Incorporando termos sazonais no modelo ARIMA, permite a captura de flutuações e tendências que têm uma repetição periódica ao longo do tempo^[2].

Devido à componente sazonal, o modelo é largamente utilizado para prever séries que possuem padrões bem definidos, como na meteorologia, com estudos demonstrando seu uso na previsão de precipitações e temperaturas^[2].

O modelo é caracterizado pelos parâmetros p , d , q que são, respectivamente, a ordem do componente autorregressivo (AR), o número de diferenças necessário para tornar a série estacionária (I), e a ordem do componente de média móvel (MA), semelhante ao ARIMA. Adicionalmente, ele incorpora termos sazonais P , D , Q e um termo S , que representa o número de períodos por temporada, o qual ajuda a descrever a sazonalidade da série de tempo, ajustando não apenas os *lags* mais recentes, mas também os *lags* sazonais^[1].

Diferente do ARIMA, a componente de diferenciação sazonal do SARIMA auxilia o modelo na identificação de tendências sazonais do modelo, se tornando mais adequada para o uso em séries sazonais não estacionárias. Assim como o ARIMA, o modelo possibilita a análise da sazonalidade das séries, obtida por diversos métodos, como a partir da análise visual dos *lags* sazonais gráficos de autocorrelação (ACF) e autocorrelação parcial (PACF).

Uma das formas de encontrar o melhor parâmetro é a partir do uso do *grid search*, buscando a melhor combinação dos hiperparâmetros do SARIMA, sazonais e não-sazonais.

O ajuste dos pesos no SARIMA é a partir da subtração do peso anterior pela derivada da função de Newton Raphson, com esse peso anterior como objeto da função^[2].

Apesar de semelhante, a componente sazonal aumenta significativamente o cálculo matemático do modelo, podendo ser generalizado como:

$$\phi(B) \Phi(B^s) \nabla^d \nabla_s^D Y_t = \theta(B) \Theta(B^s) \epsilon_t$$

Em que:

- $\phi(B)$ é o polinômio autorregressivo de ordem p (número de lags do modelo), definido pela equação $\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$;
- $\Phi(B^s)$ é o polinômio sazonal de ordem P , definido pela equação $\Phi(B^s) = 1 - \phi_1(B^s) - \dots - \phi_P(B^{Ps})$, onde s é o número de períodos de uma estação (ou sazonalidade);
- ∇^d é o operador de diferenciação não sazonal, $\nabla^d = (1 - B)^d$, onde d é a ordem de diferenciação;
- ∇_s^D é o operador de diferenciação sazonal, definido pela equação $\nabla_s^D = (1 - B^s)^D$, onde D é a ordem da diferenciação sazonal;
- Y_t é a série temporal no tempo t ;
- $\theta(B)$ é o polinômio de médias móveis de ordem q , definido pela equação $\theta(B) = 1 + \theta_1 B + \dots + \theta_q B^q$, onde q é a ordem das médias móveis;
- $\Theta(B^s)$ é o polinômio de médias móveis de ordem Q , definido pela equação $\Theta(B^s) = 1 + \theta_1 B^s + \dots + \theta_Q B^{Qs}$, onde Q é ordem de sazonalidade das partes móveis;
- ϵ_t é o termo de erro no tempo t , podendo ser modelado como um ruído branco.

Antes da aplicação do modelo SARIMA, a série Y_t é diferenciada nas ordens d e D , segundo a equação:

$$Y'_t = (1 - B)^d (1 - B^s)^D Y_t$$

Onde Y'_t é a série diferenciada.

Aplicando-se todos os termos, a expressão para o modelo SARIMA é:

$$Y'_t = c + \phi_1 Y'_{t-1} + \dots + \phi_p Y'_{t-p} - \theta_1 \epsilon_{t-1} - \dots - \theta_q \epsilon_{t-q} + \Phi_1 Y'_{t-s} \\ + \dots + \Phi_P Y'_{t-PS} - \theta_1 \epsilon_{t-s} - \dots - \theta_Q \epsilon_{t-QS} + \epsilon_t$$

3.3 Modelo LSTM

Redes Neurais Artificiais (ANNs) formam a base das modernas técnicas de aprendizado de máquina, inspiradas na estrutura e funcionamento do cérebro humano. Elas são compostas por unidades, ou "neurônios", que processam informações através de funções matemáticas e conexões entre neurônios. As redes feedforward são o tipo mais simples de ANNs, foram criadas com o objetivo da informação mover-se apenas em uma direção, da entrada para a saída, sem ciclos ou laços, as torna adequadas para uma variedade de tarefas de previsão e classificação^[7].

As Redes Neurais Recorrentes (RNNs) são uma classe de redes neurais projetadas para reconhecer padrões em sequências de dados, como séries temporais ou sequências de texto. Entretanto, as RNNs padrão enfrentam dificuldades para aprender dependências de longo prazo devido ao problema do desaparecimento do gradiente. Durante o treinamento de redes neurais através de *backpropagation*, os gradientes são computados usando a regra da cadeia. Para uma RNN, isso envolve multiplicar repetidamente gradientes através de cada etapa temporal. Matematicamente, o cálculo do gradiente de uma sequência de comprimento T pode ser demonstrado como:

$$\frac{\partial L}{\partial W} = \sum_{t=1}^T \frac{\partial L_t}{\partial W}$$

Em que:

- L_t é a perda no tempo t;
- W são os pesos da rede.

Se os valores dessas derivadas são pequenos (menores que 1), o produto ao longo de muitos passos temporais torna-se pequeno, fazendo com que o gradiente em relação a W seja suprimido, impedindo que o

modelo aprenda efetivamente as dependências de longo prazo, uma vez que os gradientes fornecem informações insuficientes para atualizar os pesos durante o treinamento.

Para contornar esse problema, as redes *Long Short-Term Memory* (LSTM) foram introduzidas por Hochreiter e Schmidhuber em 1997. As LSTMs foram projetadas especificamente para evitar o problema do desaparecimento do gradiente, permitindo à rede lembrar de informações por períodos mais longos^[3].

A arquitetura da LSTM é composta por uma série de "células" de memória. Ao contrário das unidades padrão nas RNNs, uma célula LSTM tem três portas reguladoras: a porta de esquecimento, que decide que informações descartar; a porta de entrada, que atualiza a célula de memória com novas informações; e a porta de saída, que determina o próximo estado oculto com base na célula de memória atual e na entrada.

A combinação das operações destas portas permite à LSTM decidir quando lembrar, quando esquecer e quando transmitir informações, tornando-a adequada para aprender dependências de longo prazo e sequenciais nos dados.

Comparativamente às RNNs padrão, as LSTMs têm demonstrado superioridade notável em uma série de aplicações, desde a tradução automática até a geração de texto e a análise de sentimentos, graças à sua capacidade de capturar e reter informações por períodos prolongados.

Um dos principais pontos negativos relacionado às LSTMs é o *overfitting*, que pode ser identificado na alta precisão do modelo ao conjunto de treinamento e baixa precisão no conjunto de validação, induzindo às análises incorretas. Para evitar, aplica-se formas de regularização dos modelos e/ou dos dados, sendo elas:


- *Early stopping*: regularização baseado na monitoração das métricas de erro no modelo no conjunto de validação durante o treinamento. Se o desempenho (erro) começa a piorar, o modelo

pode estar mostrando *overfitting* e o *early stopping* é ativado, terminando o treinamento naquela época^[8];

- *Dropout*: em cada etapa do treinamento, neurônios tem uma probabilidade definida de serem removidos temporariamente removidos da rede, criando uma versão mais enxuta a cada iteração, reduzindo a dependência de neurônios individuais no treinamento, forçando o modelo a aprender várias representações e ter maior capacidade de generalização^[9];

De forma geral, o diagrama (Figura 2) abaixo ilustra o funcionamento do modelo LSTM:

Figura 2 – Diagrama do Modelo LSTM



Fonte: Zhou, Dingyi & Zuo, Xiaoqing & Zhao, Zhifang^[10]. (2022)

A porta de esquecimento (f_t) é a responsável por decidir a quantidade de informação da célula anterior que será mantida para os cálculos da próxima célula. Pode ser representada como:

$$f_t = \sigma (W_f * [h_{t-1}, x_t] + b_f)$$

Em que:

- σ é a função sigmoide;
- W_f é o peso da porta de esquecimento, definido por técnicas de retropropagação;
- b_f é o viés da porta de esquecimento, com o objetivo de deslocar uma função de ativação;
- h_{t-1} é o estado oculto passado, da célula anterior;
- x_t é a entrada no tempo t .

A função sigmoide pode ser definida por:

$$f(x) = \frac{1}{1+e^{-x}}$$

A porta de entrada (i_t) é responsável por decidir quais (e o quanto) valores do estado da célula serão atualizados, por meio de uma operação por utilizando a função sigmoide, representada por:

$$i_t = \sigma (W_i * [h_{t-1}, x_t] + b_i)$$

Em que:

- W_i é o peso atribuído a porta de entrada;
- b_i é o viés da porta de entrada.

Os valores candidatos ($\tilde{C}_t$) são a versão atualizada que pode ser adicionada ao estado da célula. Eles são definidos por:

$$\tilde{C}_t = \tanh(W_c * [h_{t-1}, x_t] + b_c)$$

Em que:

- W_c é o peso atribuído ao valor candidato;
- b_c é o viés do valor candidato.

As portas de saídas (O_t) é a função que define quais partes do estado da célula vão para o estado oculto (saída do LSTM), podendo ser representada por:

$$O_t = \sigma (W_o * [h_{t-1}, x_t] + b_o)$$

Em que:

- W_o é o peso da porta de saída;
- b_o é o viés da porta de saída.

Combinando as portas citadas, o estado da célula é atualizado (C_t), combinando o esquecimento da informação anterior ($f_t * C_{t-1}$) e adicionando a nova informação ($i_t * \tilde{C}_t$), explicado pelas operações abaixo:

$$C_t = f_{t-1} * C_{t-1} + i_t * \tilde{C}_t$$

Por fim, também pode ser verificado a atualização do estado oculto, que é uma versão “filtrada” do estado da célula. Podendo ser representado como:

$$h_t = o_t * \tanh(C_t)$$

Durante o cálculo, a LSTM é capaz de preservar o gradiente do erro através de cada porta, ajustando o estado da célula C_t . A operação de multiplicação, elemento a elemento, serve para esse ajuste.

Após o início do treino do LSTM, os pesos são ajustados de forma iterativa através de *backpropagation* e métodos de cálculos. O projeto focará no *Adam*, por ser um dos principais algoritmos de atualização dos pesos^[11]. Inicialmente, o *Adam* define dois vetores, m e v , para armazenar os primeiros momentos (o equivalente ao gradiente médio) e os segundos momentos (o equivalente ao gradiente ao quadrado médio) dos gradientes, respectivamente. Definem-se dois hiperparâmetros para controlar o decaimento desses momentos, além de um erro para evitar a divisão por 0 durante os cálculos. Após isso, os gradientes são calculados, tendo suas médias móveis no vetor m e a média móvel dos seus quadrados no vetor v , ponderados pelos hiperparâmetros. Por fim, os pesos são ajustados subtraindo do peso anterior a média móvel corrigida do gradiente (último valor contido no vetor m) sobre a raiz quadrada do último valor contido no vetor v .

4. METODOLOGIA


4.1 Extração de dados e ferramentas

As 3 commodities (minério de ferro, soja e café) utilizadas no projeto foram escolhidas devido à importância para a economia brasileira, como citado na seção de introdução. Para a realização do projeto, foram utilizados os dados mensais, em reais brasileiros, dos produtos supracitados, com dados de agosto de 1998 a junho de 2023, extraídos do portal de dados internacionais Index Mundi^{[12][13][14]}, por sua credibilidade e por ser uma das principais agregadoras de dados econômicos, mesmo possuindo somente dados mensais para a janela de tempo utilizada no experimento. Sendo assim, cada série possui 299 pontos, constituídos em 3 arquivos de formato .CSV (separação de colunas com “;” e datas no formato MM/DD/AAAA), utilizados posteriormente como dados de entrada para os modelos. Os gráficos dos preços podem ser observados nas figuras 3, 4 e 5.

O algoritmo utilizado foi construído em linguagem Python, devido à vasta disponibilidade de bibliotecas que auxiliam na construção dos modelos ARIMA, SARIMA e LSTM, como as bibliotecas statsmodels^[15] e keras^[16].


Para executar o algoritmo, foi utilizado a versão 6.5.4 do software Jupyter Notebook, pela interface facilmente navegável e disponibilidade de conhecida bibliografia online.

Figura 3 – Gráfico de preços de Minério de ferro




Fonte: *Index Mundi* (2023).

Figura 4 – Gráfico de preços de Café



Fonte: *Index Mundi* (2023).

Figura 5 – Gráfico de preços de Soja



Fonte: *Index Mundi* (2023).

4.2 Entrada e Definições Iniciais

O algoritmo inicia com a instalação das bibliotecas necessárias, sendo eles *pmdarima* (utilizada para o “treinar” os modelos ARIMA e SARIMA), *tabulate* (facilita da construção de tabelas), *pandas-profiling* (auxilia na manipulação de dados) e *tensorflow* (poderosa para a construção das redes neurais que resultam o LSTM). São importados os diversos pacotes necessários para a construção e posterior execução do algoritmo.

Com os pacotes devidamente instalados e identificados, cria-se a variável *path*, que receberá a semente do código: o arquivo .CSV contendo os dados históricos de cada produto, realizando as devidas transformações para ser utilizado como entrada apropriada aos modelos. Para confirmar visualmente se a informação está apropriada, utiliza-se a função “*plot*” para construir um gráfico dos preços ao longo do tempo. Nesse mesmo bloco, é estabelecido previamente o número de dados (ou meses) a frente que serão previstos pelos modelos. No caso, foi utilizado o número 36, ou seja, os modelos estimaram os preços de cada commodities para os 36 meses subsequentes ao último dado (junho/2023). O número foi utilizado por se

tratar de um horizonte que representa o arredondamento superior de 10% do número de dados de entrada (29,9 meses) e por ser um período que pode ser consolidado em anos (36 meses é equivalente a 3 anos).

Foram decompostas as séries para visualização gráfica das séries tendência, sazonalidade, erros residuais, autocorrelação e autocorrelação parcial, de forma a serem utilizadas para validação dos dados futuros (por exemplo, caso os modelos prevejam uma queda nos preços e se segue a sazonalidade prevista para a série).

Foram estabelecidos os tamanhos das séries de dados utilizados para o treino dos modelos e para os testes. Devido ao tamanho da série pequena (299 dados no total), a literatura indica que sejam estabelecidas séries de treino de tamanho relevante em relação a série total, sendo assim, foi estabelecido o uso de 90% da série (ou seja, do dado 0 – agosto/1998 – até o dado de número 270) para treino do algoritmo e os 10% restantes para a validação do modelo.

4.3 Modelos

O primeiro modelo a ser executado é o SARIMA, principalmente devido ao número de hiperparâmetros elevado, totalizando 7 (p , d , q , P , D , Q , S), em relação aos somente 3 no ARIMA. Inicialmente, é construído um *looping* (processo chamado de *grid search*) para verificar quais são os melhores parâmetros para o modelo, de forma a obter as melhores métricas de erro. As métricas de erro utilizadas na observação são: *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE) e *Mean Absolute Percentage Error* (MAPE). A MAE é o erro médio absoluto, resultado da média das diferenças (erro) entre os modelos previstos para o período de validação e os valores reais naquele período, escolhida por diminuir o impacto dos *outliers* da série. O MSE é o erro médio quadrado, diferença quadrática média entre os erros, escolhida por penalizar erros maiores, sendo mais sensíveis a *outliers*. O RMSE é a raiz quadrada da média dos quadrados dos erros, escolhida por oferecer vantagem frente ao RMSE por estar na mesma unidade dos dados de entrada, facilitando a interpretação. O MAPE é a média do valor absoluto dos erros em termos

percentuais, escolhido pela facilidade de interpretação ao utilizar séries diferentes.

Sendo assim, o *grid search* é iniciado variando os parâmetros p , d , q , P , D , Q entre 0 e 3, enquanto S é variado entre 2 e 13, criando diversas variações e consumindo parte majoritária do poder de processamento da máquina utilizada, demanda cerca de 72 horas ininterruptas para executar o modelo. Os números 0 e 3 foram escolhidos com o objetivo de limitar a adaptação do modelo a séries sem excessiva volatilidade e evitar o *overfitting*. A faixa da variável S (sazonalidade), foi escolhida pela possibilidade de capturar diversos padrões temporais da amostra, sejam eles trimestrais, semianuais, anuais ou que possuem outros padrões. Após os extensivos testes, é extraído uma planilha com as diversas combinações testadas e suas respectivas métricas de erro. Com a planilha extraída, se estabeleceu cortes para alguns parâmetros (R^2 relevante, ou seja, acima de 0 e abaixo de 100, e MAPE acima de 0) e buscou-se a maior proporção entre R^2 e MAPE, de forma a dar mais relevância às combinações que possuem equilíbrios razoáveis entre ajuste e erro percentual.

O MAPE foi escolhido como métrica principal de erro para o estudo por ser menos suscetível a outliers e pela sua capacidade de ser ajustado às mais variadas séries, visto que os modelos seriam usados para as 3 commodities objetos do estudo.

No ARIMA, o número reduzido de hiperparâmetros ($3 - p, d, q$), possibilita testes mais extensivos, de forma que foram definidos que os parâmetros variariam de 0 a 13, semelhantemente ao SARIMA, buscando razoabilidade entre as métricas de ajuste e erro. Como o modelo ARIMA não possui variável sazonal, foi definido uma faixa mais longa de teste, visto a fragilidade do modelo em prever formas sazonais.

O último modelo a ser executado é o LSTM. De forma semelhante aos anteriores, o algoritmo realiza o chamado *grid search* testando diversas combinações de parâmetros, entre *batch_size* (define o tamanho das amostras do fragmento de treino que será utilizada nas previsões), *units* (unidades de processamento, ou neurônios, em que serão iteradas essas amostras) e *epochs* (número de vezes que todas as *units* serão percorridas).

Visto o nível de complexidade do modelo e tempo para processamento das redes neurais, foram estabelecidos 3 possíveis valores para os parâmetros, escolhidos a partir de ampla pesquisa e verificações posteriores.

Os parâmetros 150, 200 e 250 para o número de épocas (*epochs*), ou seja, o número de vezes que uma amostra dos dados de treino (*batch*) todas as células (*units*), foram utilizados para a execução ágil do looping, visto que o modelo possui exigência computacional elevada. O mesmo foi aplicado para o número de *units*.

Após testes empíricos resultarem em métricas de erro expressivamente elevadas para *batch sizes* recomendados por documentações técnicas^[17] (múltiplos de 8 para melhor alocação de processamento utilizando GPU), foram testados outros tamanhos para esse parâmetro, em busca do melhor R^2 . Para isso, testou-se tamanhos elevados em relação ao conjunto de treino (240 dados), testando 50, 100 e 150 como parâmetros para essa variável.

Com todos os parâmetros otimizados definidos, é realizada as previsões, compara-se o previsto à série de teste, as métricas de erro e os valores futuros, para cada modelo.

5. RESULTADOS E DISCUSSÃO

Definidas as combinações de parâmetros e critérios de corte para o SARIMA, obteve-se as seguintes possibilidades para minério de ferro, café e soja, respectivamente (serão apresentados os 10 maiores valores de proporção entre R^2 e MAPE, considerando os critérios supracitados; caso possua mais de 10 combinações “habilitadas”, a lista completa consta no apêndice A, para o SARIMA, apêndice B para ARIMA, e no apêndice C para o LSTM):

Tabela 1 – Possíveis combinações de SARIMA para Ferro

p	d	q	P	D	Q	S	mse	rmse	mape	mae	r2	aic	bic	r2/MAPE
1	2	0	2	0	2	11	3.72	1.93	18.34	1.29	0.23	-60.54	-39.74	0.0123
0	2	0	1	1	1	12	3.69	1.92	19.13	1.32	0.23	-14.08	-3.83	0.0122
1	2	0	1	0	1	11	3.74	1.93	18.34	1.29	0.22	-64.54	-50.67	0.0121
1	2	0	1	0	2	11	3.76	1.94	18.31	1.29	0.22	-62.58	-45.24	0.0120
1	2	0	2	0	1	11	3.76	1.94	18.30	1.29	0.22	-62.60	-45.26	0.0120
0	2	0	0	1	2	12	3.72	1.93	19.00	1.32	0.23	-14.22	-3.97	0.0120
1	2	0	2	1	2	6	3.67	1.91	19.98	1.34	0.24	-40.55	-19.90	0.0119
0	2	0	0	1	1	12	3.66	1.91	20.37	1.35	0.24	-15.06	-8.23	0.0118
2	2	0	1	1	2	12	3.70	1.92	19.63	1.33	0.23	-61.61	-41.11	0.0117
0	1	0	0	1	0	2	3.64	1.91	20.80	1.35	0.24	38.38	41.84	0.0117

Tabela 2 – Possíveis combinações de SARIMA para café

p	d	q	P	D	Q	S	mse	rmse	mape	mae	r2	aic	bic	r2/MAPE
1	2	1	2	2	1	3	14.16	3.76	13.94	2.84	0.74	392.82	413.48	0.053
0	2	1	1	2	1	4	14.00	3.74	14.12	2.85	0.74	412.26	425.99	0.052
2	2	0	0	2	2	10	13.57	3.68	14.31	2.84	0.75	422.36	439.26	0.052
1	2	0	0	2	2	10	13.91	3.73	14.22	2.87	0.74	425.91	439.43	0.052
0	2	1	2	2	1	3	15.07	3.88	13.82	2.93	0.72	396.23	413.45	0.052
0	2	1	0	2	1	6	14.87	3.86	13.98	2.90	0.72	472.63	482.88	0.052
2	2	1	1	2	1	4	13.90	3.73	14.48	2.86	0.74	404.57	425.17	0.051
2	2	1	2	2	1	3	14.33	3.79	14.46	2.86	0.73	393.92	418.01	0.051
0	2	0	2	0	2	4	14.44	3.80	14.52	2.86	0.73	412.58	429.92	0.050
0	2	0	1	1	1	3	14.12	3.76	14.65	2.90	0.74	419.59	429.96	0.050

Tabela 3 – Possíveis combinações de SARIMA para soja

p	d	q	P	D	Q	S	mse	rmse	mape	mae	r2	aic	bic	r2/MAPE
2	2	1	0	2	1	9	162,300	403	15	345	0.773	2,573	2,590	0.053
2	2	0	2	1	0	7	160,522	401	15	344	0.776	2,609	2,627	0.053
2	2	1	1	2	1	7	167,783	410	15	348	0.766	2,542	2,563	0.052
1	2	1	1	2	1	7	168,761	411	15	348	0.764	2,541	2,558	0.052
2	2	0	2	2	1	10	182,881	428	14	340	0.745	2,510	2,530	0.052
0	2	1	1	2	1	7	158,989	399	15	344	0.778	2,545	2,558	0.052
1	2	1	0	2	1	9	156,992	396	15	344	0.781	2,574	2,588	0.052
2	2	1	0	2	1	10	167,323	409	15	333	0.766	2,573	2,589	0.052
0	2	0	0	1	0	10	167,578	409	15	343	0.766	2,761	2,765	0.052
0	2	1	0	2	1	10	168,138	410	15	334	0.765	2,576	2,586	0.052

Definidas as combinações de parâmetros e critérios de corte para o ARIMA, obteve-se as seguintes possibilidades para minério de ferro e soja,

respectivamente (serão apresentados os 10 maiores valores de proporção entre R^2 e MAPE, considerando os critérios supracitados; caso possua mais de 10 combinações “habilitadas”, a lista completa constará no apêndice B):

Tabela 4 – Possíveis combinações de ARIMA para Minério de Ferro

p	d	q	mse	rmse	mape	mae	r2	aic	bic	r2/MAPE
3	6	8	3.98	2.00	18.23	1.31	0.17	-18.45	22.97	0.009
1	3	1	4.16	2.04	19.28	1.37	0.14	-58.45	-48.06	0.007
1	2	0	4.37	2.09	18.86	1.36	0.09	-67.72	-60.79	0.005

Tabela 5 – Possíveis combinações de ARIMA para soja

p	d	q	mse	rmse	mape	mae	r2	aic	bic	r2/MAPE
11	6	12	80,333	283	12	244	0.89	2,682	2,765	0.07
6	6	11	137,649	371	14	313	0.81	2,722	2,784	0.06
5	6	12	194,159	441	13	350	0.73	2,707	2,769	0.05
12	4	8	181,877	426	15	348	0.75	2,623	2,696	0.05
1	5	8	224,804	474	14	371	0.69	2,670	2,704	0.05
2	5	9	205,810	454	15	370	0.71	2,670	2,712	0.05
5	5	12	228,805	478	14	368	0.68	2,648	2,711	0.05
6	4	5	166,239	408	16	356	0.77	2,620	2,661	0.05
3	5	11	229,209	479	14	360	0.68	2,679	2,731	0.05
7	4	6	196,398	443	16	382	0.73	2,619	2,668	0.05

Tabela 6 – Possíveis combinações de ARIMA para café

p	d	q	mse	rmse	mape	mae	r2	aic	bic	r2/MAPE
7	4	2	14.8	3.8	14.2	2.9	0.72	347.7	382.3	0.051
7	3	3	13.9	3.7	14.8	2.9	0.74	335.6	373.7	0.050
10	4	7	15.1	3.9	14.4	3.0	0.72	362.0	424.3	0.050
10	3	7	15.1	3.9	14.4	2.9	0.72	351.8	414.1	0.050
6	3	2	14.7	3.8	14.6	2.9	0.73	341.7	372.8	0.050
12	4	8	15.4	3.9	14.3	3.0	0.71	355.3	427.9	0.050
5	3	1	13.5	3.7	15.1	2.9	0.75	340.1	364.3	0.050
11	4	8	14.7	3.8	14.7	2.9	0.73	365.4	434.6	0.049
11	4	7	16.1	4.0	14.4	3.0	0.70	359.4	425.1	0.049
5	2	0	15.1	3.9	14.8	2.9	0.72	330.7	351.5	0.049

Analisando as tabelas de ARIMA, de acordo com os critérios estabelecidos, para o minério de ferro, o melhor ajuste utilizando o modelo ARIMA é onde os parâmetros (p, d, q) são iguais a (3, 6, 8), para soja (10, 4, 4) e para café (7, 4, 2).

Considerando os critérios estabelecidos, as métricas de erro foram comparadas para cada modelo e o gráfico, confrontando os dados reais (série de teste) e os previstos pelos modelos para cada produto:

Tabela 6 – Métricas de erro por modelo para Minério de ferro

Métrica	SARIMA	ARIMA	LSTM
MSE	3.7	4.0	1.9
RMSE	1.9	2.0	1.4
MAE	1.3	1.3	1.2
MAPE	18.3	18.2	17.7
R ²	0.253	0.172	0.522


Tabela 7 – Métricas de erro por modelo para café

Métrica	SARIMA	ARIMA	LSTM
MSE	14.1	14.8	2.4
RMSE	3.8	3.8	1.4
MAE	2.9	2.9	1.3
MAPE	13.9	14.2	5.
R ²	0.740	0.718	0.948

Tabela 8 – Métricas de erro por modelo para soja


Métrica	SARIMA	ARIMA	LSTM
MSE	162,300	80,332	22,729
RMSE	402.9	283.4	162.6
MAE	345.1	244.2	132.8
MAPE	14.7	12.2	4.6
R ²	0.773	0.888	0.964

Figura 9 – Gráfico de comparação dos dados reais e previstos por modelo para Minério de ferro




Fonte: O Autor – Jupyter Notebook (2023).

Figura 10 – Gráfico de comparação dos dados reais e previstos por modelo para café



Fonte: O Autor – Jupyter Notebook (2023).


Figura 11 – Gráfico de comparação dos dados reais e previstos por modelo para soja



Fonte: O Autor – Jupyter Notebook (2023).


Como definido no início do experimento, foram previstos os preços mensais dos 36 meses subsequentes ao dado final da série (junho de 2023), como forma de demonstrar o uso prática dos modelos, para cada produto. Os resultados podem ser encontrados nas figuras 12, 13 e 14.

Figura 12 – Gráfico dos 36 dados futuros para Minério de ferro




Fonte: O Autor – Jupyter Notebook (2023).

Figura 13 – Gráfico dos 36 dados futuros para café



Fonte: O Autor – Jupyter Notebook (2023).

Figura 14 – Gráfico dos 36 dados futuros para soja



Fonte: O Autor – Jupyter Notebook (2023).

Uma vez que o projeto proposto visa encontrar o melhor modelo, baseado em métricas de ajuste (R^2) e erro (MAPE), com os melhores ajustes, considerando o poder computacional limitado, foi constatado que o modelo LSTM apresentou métricas de erro ligeiramente superiores para as 3 commodities. Analisando a série de testes, pode-se dizer que os modelos, nos testes estabelecidos, apresentam números pouco conectados com os últimos dados apresentados, podendo ser constatado certo *overfitting*, mesmo sem uma testagem mais ampla de parâmetros.

A principal dificuldade desse projeto se deu pelo tamanho limitado do conjunto de dados e pelo poder computacional. Por se tratar de um conjunto de dados com apenas 299 preços, o modelo está muito suscetível a diversos ruídos advindos do aprendizado com a série de treino, podendo prejudicar a predição de novos dados. Além disso, o fator também limita o uso de técnicas para evitar *overfitting*, mais relacionado com o modelo LSTM. O uso do *early stop* se torna dificultado, pois pode acionar uma parada precoce do modelo, visto que, por se tratar de poucos dados, pode não mostrar melhoras expressivas nas métricas de erro em poucas épocas.

O poder computacional foi o outro gargalo do projeto. Como os testes são realizados um a um, buscando a melhor combinação entre diversos fatores, para 3 modelos e 3 commodities, o algoritmo demoraria cerca de 3 dias para ser executado por completo, com os recursos computacionais disponíveis. Foram testados diversos parâmetros, inclusive de maior magnitude, porém aumentou consideravelmente o tempo de processamento. Por exemplo, enquanto o modelo SARIMA, variando de 0 a 3 para os parâmetros p , d , q , P , D , Q e de 0 a 13 para o parâmetro S , demorariam cerca de 3 horas para encontrar as combinações com melhores métricas, variando de 0 a 4 e de 0 a 17 demoraria cerca de 72 horas para ser executado por completo de encontrar a melhor combinação. Além disso, a exigência computacional para o processamento de diversas possibilidades para os parâmetros do LSTM ocasiona múltiplos desligamentos súbitos do ambiente de execução do Python, necessitando de uma maior limitação dos possíveis parâmetros.

A limitação das possibilidades também se mostrou como um problema maior para o caso do LSTM. Segunda documentações técnicas^[18], recomenda-se o uso de *batch sizes* de múltiplos de 8 ou 4, pois otimizaria a performance do processamento com o uso de GPU. Empiricamente, o modelo apresentou reações contrárias a isso e, além de apresentar prolongar o tempo necessário para o processamento, mostrou resultados insatisfatórios, fora dos parâmetros estabelecidos na pesquisa. Sendo assim, foi utilizado números de *batch* alternativos, começando por múltiplos de 10 e múltiplos de 50, mostrando maior eficiência entre os múltiplos de 50 e sendo determinado 3 possíveis valores para o parâmetro: 50, 100 e 150.

As séries mensais foram utilizadas por não possuir outra periodicidade no portal Index Mundi, principal base gratuita para os produtos usados no estudo. Se o projeto dispusesse de séries mais extensas, os modelos poderiam apresentar um volume maior de treinos, com projeções mais ajustadas e contornando os problemas relacionados a séries menores, como a generalização dos modelos. Poderia também ter sido usado técnicas robustas para evitar o overfitting, como *dropout* ou *early stop*.

6. CONCLUSÃO

O estudo apresentado mostra as possibilidades do uso de alguns dos principais modelos de rede neural e estatísticos para a previsão de 3 produtos que figuram entre as commodities mais importantes para as exportações no Brasil. Estabelecendo critérios definidos de ajustes e métrica de erro, foi possível encontrar quais dos modelos analisados se ajustariam melhor às previsões de preços daqueles produtos.

Apesar dos resultados satisfatórios obtidos pelos modelos, principalmente pelo LSTM, uma série de dados mais longa possibilitaria os modelos serem treinados de forma mais robusta e ampliar sua capacidade de prever os novos preços. Além disso, possibilitaria o uso de técnicas que, teoricamente, melhorariam a performance dos modelos como um todo e evitaria o *overfitting*, como no caso do uso do *dropout* ou *early stop*. Outro fator que auxiliaria na melhora constante dos modelos seria o poder computacional mais elevado, em relação ao utilizado no experimento.

Com as considerações acima, pode-se constatar que o projeto pode apresentar potenciais melhorias para o futuro, podendo ser replicado para diversas outras aplicações relacionadas a previsão de preços, sob diversas janelas de tempo.

7. REFERÊNCIAS

- [1] Hyndman, R.J., & Athanasopoulos, G. (2018). **Forecasting: principles and practice.**
- [2] Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). **Time series analysis: forecasting and control.** John Wiley & Sons.
- [3] Hochreiter, S., & Schmidhuber, J. (1997). **Long short-term memory. Neural computation**
- [4] Organização das Nações Unidas para Alimentação e Agricultura. (2020). **The State of Agricultural Commodity Markets 2020.**
- [5] Associação Mundial do Aço. (2019). **Steel Statistical Yearbook 2019.**
- [6] <https://oec.world/en/visualize/stacked/hs92/export/show/all/21201.52601.20901/2015.2021>
- [7] Goodfellow, I., Bengio, Y., & Courville, A. (2016). **Deep Learning.** MIT Press.
- [8] Prechelt, L. (1998). Early Stopping - But When?. In **Neural Networks: Tricks of the Trade** (pp. 55-69). Springer, Berlin, Heidelberg.
- [9] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. **Journal of Machine Learning Research**, 15, 1929-1958.
- [10] Zhou, Dingyi & Zuo, Xiaoqing & Zhao, Zhifang. (2022). **Constructing a Large-Scale Urban Land Subsidence Prediction Method Based on Neural Network Algorithm from the Perspective of Multiple Factors.** **Remote Sensing**. 14. 1803. 10.3390/rs14081803.
- [11] Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. **arXiv preprint arXiv:1412.6980**
- [12] <https://www.indexmundi.com/commodities/?commodity=soybeans&months=240¤cy=brl>
- [13] <https://www.indexmundi.com/commodities/?commodity=iron-ore&months=360¤cy=brl>
- [14] <https://www.indexmundi.com/commodities/?commodity=other-mild-arabicas-coffee¤cy=brl>

- [15] <https://www.statsmodels.org/stable/index.html>
- [16] <https://keras.io/>
- [17] https://scikit-learn.org/stable/modules/generated/sklearn.metrics.mean_squared_error.html
- [18] <https://docs.nvidia.com/deeplearning/performance/dl-performance-recurrent/index.html>

8. APÊNDICE A

Parâmetros dentro dos critérios para o minério de ferro utilizando o SARIMA.

p	d	q	P	D	Q	S	mse	rmse	mape	mae	r2	aic	bic	r2/MAPE
1	2	0	2	0	2	11	3.72	1.93	18.34	1.29	0.23	-60.54	-39.74	0.0123
0	2	0	1	1	1	12	3.69	1.92	19.13	1.32	0.23	-14.08	-3.83	0.0122
1	2	0	1	0	1	11	3.74	1.93	18.34	1.29	0.22	-64.54	-50.67	0.0121
1	2	0	1	0	2	11	3.76	1.94	18.31	1.29	0.22	-62.58	-45.24	0.0120
1	2	0	2	0	1	11	3.76	1.94	18.30	1.29	0.22	-62.60	-45.26	0.0120
0	2	0	0	1	2	12	3.72	1.93	19.00	1.32	0.23	-14.22	-3.97	0.0120
1	2	0	2	1	2	6	3.67	1.91	19.98	1.34	0.24	-40.55	-19.90	0.0119
0	2	0	0	1	1	12	3.66	1.91	20.37	1.35	0.24	-15.06	-8.23	0.0118
2	2	0	1	1	2	12	3.70	1.92	19.63	1.33	0.23	-61.61	-41.11	0.0117
0	1	0	0	1	0	2	3.64	1.91	20.80	1.35	0.24	38.38	41.84	0.0117
1	2	0	1	1	2	6	3.67	1.92	20.33	1.34	0.24	-42.14	-24.93	0.0117
2	2	0	0	1	1	12	3.69	1.92	19.90	1.34	0.23	-64.26	-50.60	0.0117
0	2	0	1	1	2	12	3.67	1.91	20.58	1.35	0.24	-11.24	2.43	0.0116
0	2	0	1	1	2	5	3.74	1.93	19.46	1.33	0.22	-29.14	-15.35	0.0115
0	2	0	2	0	2	4	3.79	1.95	18.65	1.31	0.21	-49.56	-32.22	0.0114
1	2	0	1	0	1	8	3.73	1.93	19.78	1.34	0.22	-64.91	-51.03	0.0114
0	2	0	0	1	1	10	3.74	1.93	20.05	1.35	0.22	-14.39	-7.54	0.0111
0	2	0	0	1	1	5	3.74	1.94	20.16	1.35	0.22	-31.01	-24.12	0.0110
0	2	0	2	0	2	3	3.82	1.96	18.72	1.32	0.21	-48.34	-31.00	0.0110
0	2	0	1	1	1	5	3.73	1.93	20.52	1.36	0.23	-30.09	-19.75	0.0110
1	2	0	0	1	1	3	3.80	1.95	19.41	1.34	0.21	-51.24	-40.88	0.0109
0	2	0	0	1	2	5	3.74	1.93	20.57	1.36	0.22	-29.92	-19.58	0.0109
0	2	0	1	1	2	10	3.74	1.93	20.49	1.36	0.22	-10.75	2.95	0.0109
1	2	0	2	1	1	5	3.78	1.94	20.03	1.35	0.22	-44.36	-27.13	0.0107
0	2	0	2	1	1	12	3.85	1.96	19.04	1.33	0.20	-13.34	0.33	0.0105
0	2	0	1	1	1	8	3.83	1.96	19.58	1.35	0.20	-19.52	-9.22	0.0104
0	2	0	0	1	2	8	3.83	1.96	19.62	1.35	0.20	-19.52	-9.22	0.0104
0	2	0	2	1	2	5	3.77	1.94	20.81	1.37	0.22	-27.95	-10.72	0.0104

1	2	0	2	0	2	12	3.91	1.98	18.20	1.30	0.19	-68.59	-47.78	0.0104
1	2	0	1	1	2	3	3.87	1.97	18.98	1.33	0.20	-48.76	-31.48	0.0103
1	2	0	2	1	2	8	3.84	1.96	19.92	1.36	0.20	-36.02	-15.42	0.0101
0	2	0	2	1	2	8	3.85	1.96	19.76	1.36	0.20	-16.90	0.27	0.0101
0	2	0	0	1	1	8	3.87	1.97	19.48	1.35	0.20	-21.51	-14.64	0.0101
1	2	0	0	0	2	11	3.92	1.98	18.44	1.31	0.18	-64.41	-50.54	0.0100
0	2	0	2	1	2	4	3.85	1.96	20.06	1.36	0.20	-26.63	-9.38	0.0100
0	2	0	2	1	1	4	3.86	1.97	20.02	1.36	0.20	-28.42	-14.61	0.0099
1	1	0	0	2	1	3	3.91	1.98	19.47	1.35	0.19	23.10	33.44	0.0097
1	2	0	2	1	2	3	3.93	1.98	19.15	1.34	0.18	-45.57	-24.83	0.0096
1	2	0	0	1	1	6	3.94	1.99	18.83	1.33	0.18	-45.57	-35.24	0.0096
0	2	0	2	1	1	8	3.92	1.98	19.45	1.35	0.19	-17.56	-3.83	0.0096
0	2	0	1	1	1	4	3.90	1.97	19.94	1.37	0.19	-30.40	-20.04	0.0095
0	2	0	0	1	2	4	3.90	1.98	19.96	1.37	0.19	-30.39	-20.04	0.0095
1	2	0	2	0	2	4	3.96	1.99	18.79	1.33	0.18	-66.78	-45.98	0.0094
0	2	0	0	1	1	4	3.90	1.98	20.18	1.37	0.19	-32.34	-25.44	0.0094
1	1	0	0	2	1	8	3.93	1.98	19.83	1.36	0.18	33.95	44.16	0.0093
1	2	0	2	0	0	11	3.99	2.00	18.49	1.32	0.17	-64.33	-50.46	0.0093
0	2	0	1	1	2	4	3.91	1.98	20.36	1.38	0.19	-28.36	-14.56	0.0093
1	2	0	0	1	2	10	3.96	1.99	19.27	1.35	0.18	-29.69	-15.99	0.0092
1	2	0	0	1	2	3	3.96	1.99	19.12	1.35	0.18	-49.48	-35.66	0.0092
1	2	0	2	0	1	4	3.99	2.00	18.84	1.34	0.17	-62.91	-45.57	0.0091
1	2	0	1	1	1	3	3.98	2.00	19.13	1.35	0.17	-49.50	-35.68	0.0091
1	2	0	0	0	1	11	4.01	2.00	18.57	1.33	0.17	-66.25	-55.84	0.0090
1	2	0	1	0	2	4	4.00	2.00	18.85	1.34	0.17	-62.92	-45.58	0.0090
1	1	0	0	1	0	3	4.01	2.00	18.75	1.33	0.17	5.10	12.02	0.0089
1	2	0	1	0	0	11	4.03	2.01	18.58	1.33	0.16	-66.22	-55.82	0.0088
0	2	0	1	1	1	3	4.01	2.00	19.10	1.35	0.17	-34.17	-23.81	0.0088
1	2	0	2	0	2	8	4.00	2.00	19.43	1.36	0.17	-63.39	-42.58	0.0087
1	2	0	1	1	1	10	4.02	2.00	19.33	1.36	0.17	-29.79	-16.09	0.0085
2	2	0	2	1	2	7	3.97	1.99	20.49	1.39	0.17	-66.80	-42.74	0.0085
1	2	0	2	1	1	10	4.02	2.01	19.33	1.36	0.16	-27.79	-10.67	0.0085
1	2	0	1	1	2	8	4.01	2.00	19.49	1.36	0.17	-37.74	-20.58	0.0085
1	1	0	0	1	0	2	3.89	1.97	22.67	1.42	0.19	36.51	43.44	0.0085
1	2	0	1	1	2	10	3.92	1.98	22.09	1.41	0.19	-25.53	-8.41	0.0084
0	2	0	0	1	2	3	4.05	2.01	19.11	1.35	0.16	-34.15	-23.78	0.0083
0	1	1	0	2	1	8	4.03	2.01	19.77	1.37	0.16	27.16	37.37	0.0082
2	2	0	1	1	1	5	4.06	2.02	19.04	1.35	0.16	-77.28	-60.04	0.0082
2	2	0	2	1	1	4	4.07	2.02	19.13	1.36	0.16	-78.80	-58.09	0.0081
1	2	0	0	1	1	10	3.95	1.99	22.16	1.41	0.18	-29.13	-18.86	0.0081
2	2	0	0	1	2	5	4.08	2.02	19.04	1.35	0.15	-77.20	-59.97	0.0080
1	2	0	1	1	1	6	4.11	2.03	18.81	1.35	0.15	-43.64	-29.87	0.0078
1	2	0	1	1	2	5	3.97	1.99	22.44	1.42	0.17	-43.48	-26.24	0.0078
1	2	0	2	1	2	4	3.99	2.00	22.10	1.42	0.17	-43.62	-22.91	0.0077
1	2	0	0	1	1	2	4.11	2.03	19.24	1.36	0.15	-53.75	-43.37	0.0076

0	2	0	1	1	2	8	4.11	2.03	19.46	1.37	0.15	-18.55	-4.81	0.0075
2	2	0	2	1	2	5	4.12	2.03	19.25	1.36	0.14	-74.82	-50.69	0.0075
1	2	0	0	1	2	6	4.14	2.04	18.82	1.35	0.14	-43.65	-29.88	0.0074
0	2	0	2	1	2	12	4.14	2.04	18.93	1.36	0.14	-11.93	5.15	0.0074
2	2	0	0	1	2	7	4.13	2.03	19.69	1.38	0.14	-65.31	-48.12	0.0072
0	2	0	2	1	1	5	4.15	2.04	19.21	1.36	0.14	-30.01	-16.22	0.0072
1	1	0	0	1	0	8	4.15	2.04	19.26	1.36	0.14	-2.89	3.99	0.0072
2	2	0	1	1	1	7	4.14	2.03	19.68	1.38	0.14	-65.31	-48.11	0.0072
1	2	0	0	0	2	4	4.18	2.04	18.74	1.35	0.13	-63.82	-49.95	0.0071
1	2	0	2	1	2	12	4.05	2.01	22.46	1.44	0.16	-30.60	-10.11	0.0070
2	2	0	1	1	2	5	4.17	2.04	19.06	1.36	0.13	-75.98	-55.30	0.0070
2	2	0	0	1	1	7	4.16	2.04	19.68	1.38	0.14	-67.30	-53.55	0.0070
1	2	0	1	0	0	8	4.19	2.05	18.72	1.35	0.13	-65.74	-55.34	0.0069
1	2	0	2	0	0	4	4.20	2.05	18.75	1.35	0.13	-63.81	-49.94	0.0068
1	2	0	0	0	1	8	4.21	2.05	18.73	1.35	0.13	-65.74	-55.34	0.0067
1	2	0	2	0	2	7	4.20	2.05	18.90	1.35	0.13	-65.42	-44.61	0.0067
1	2	0	1	0	0	5	4.21	2.05	18.68	1.35	0.12	-66.25	-55.84	0.0067
2	2	0	0	2	2	4	4.14	2.03	21.09	1.42	0.14	-35.97	-18.80	0.0067
1	2	0	0	0	1	5	4.22	2.05	18.68	1.35	0.12	-66.16	-55.76	0.0066
1	1	1	0	2	1	2	4.22	2.05	19.31	1.37	0.12	-38.64	-24.82	0.0064
1	2	0	2	0	1	9	4.26	2.06	18.76	1.35	0.12	-61.75	-44.41	0.0062
1	2	0	0	1	1	5	4.13	2.03	23.12	1.46	0.14	-45.81	-35.47	0.0062
1	2	0	2	0	0	9	4.26	2.06	18.76	1.35	0.12	-63.75	-49.88	0.0061
0	2	0	1	1	2	3	4.25	2.06	19.21	1.37	0.12	-31.94	-18.12	0.0061
1	2	0	0	0	2	9	4.27	2.07	18.77	1.35	0.11	-63.75	-49.88	0.0060
1	2	0	0	0	1	9	4.28	2.07	18.78	1.35	0.11	-65.75	-55.34	0.0059
1	2	0	1	0	0	9	4.28	2.07	18.78	1.35	0.11	-65.75	-55.34	0.0059
1	2	0	1	0	2	9	4.28	2.07	18.78	1.35	0.11	-61.75	-44.41	0.0059
1	2	0	1	0	1	9	4.28	2.07	18.78	1.35	0.11	-63.75	-49.88	0.0059
0	1	0	0	2	1	2	4.16	2.04	23.22	1.46	0.14	51.60	58.52	0.0059
0	2	0	2	1	2	3	4.28	2.07	19.00	1.37	0.11	-30.76	-13.48	0.0058
2	2	0	0	1	1	5	4.29	2.07	19.18	1.37	0.11	-78.76	-64.98	0.0057
1	2	0	2	1	1	3	4.29	2.07	19.24	1.38	0.11	-47.77	-30.49	0.0057
2	2	0	2	1	2	6	4.30	2.07	19.02	1.37	0.11	-73.59	-49.49	0.0056
2	2	0	1	1	2	6	4.31	2.07	18.97	1.37	0.11	-75.03	-54.38	0.0056
0	2	1	0	2	1	8	4.24	2.06	21.63	1.45	0.12	55.06	65.25	0.0055
2	2	0	1	2	2	4	4.25	2.06	21.90	1.45	0.12	-35.44	-14.84	0.0054
1	2	0	0	2	2	6	4.29	2.07	20.45	1.43	0.11	8.61	22.28	0.0053
1	1	1	0	2	1	8	4.31	2.08	19.76	1.39	0.10	24.20	37.81	0.0053
1	2	0	2	1	1	12	4.22	2.05	23.47	1.48	0.12	-32.50	-15.42	0.0052
1	2	0	1	0	1	4	4.34	2.08	18.84	1.36	0.10	-63.80	-49.92	0.0052
1	2	0	2	1	1	8	4.24	2.06	22.94	1.47	0.12	-35.92	-18.75	0.0052
2	2	0	0	1	1	10	4.35	2.08	19.11	1.37	0.10	-61.67	-47.97	0.0051
1	2	0	1	0	0	7	4.35	2.09	18.84	1.36	0.10	-65.75	-55.35	0.0051
1	2	0	0	0	1	7	4.36	2.09	18.85	1.36	0.09	-65.76	-55.35	0.0050

1	2	0	1	0	2	8	4.36	2.09	19.06	1.37	0.09	-64.40	-47.06	0.0049
1	2	0	1	0	0	4	4.37	2.09	18.88	1.36	0.09	-65.79	-55.39	0.0049
1	2	0	0	0	0	2	4.37	2.09	18.86	1.36	0.09	-67.72	-60.79	0.0049
1	2	0	0	0	0	3	4.37	2.09	18.86	1.36	0.09	-67.72	-60.79	0.0049
1	2	0	0	0	0	4	4.37	2.09	18.86	1.36	0.09	-67.72	-60.79	0.0049
1	2	0	0	0	0	5	4.37	2.09	18.86	1.36	0.09	-67.72	-60.79	0.0049
1	2	0	0	0	0	6	4.37	2.09	18.86	1.36	0.09	-67.72	-60.79	0.0049
1	2	0	0	0	0	7	4.37	2.09	18.86	1.36	0.09	-67.72	-60.79	0.0049
1	2	0	0	0	0	8	4.37	2.09	18.86	1.36	0.09	-67.72	-60.79	0.0049
1	2	0	0	0	0	9	4.37	2.09	18.86	1.36	0.09	-67.72	-60.79	0.0049
1	2	0	0	0	0	10	4.37	2.09	18.86	1.36	0.09	-67.72	-60.79	0.0049
1	2	0	0	0	0	11	4.37	2.09	18.86	1.36	0.09	-67.72	-60.79	0.0049
1	2	0	0	0	0	12	4.37	2.09	18.86	1.36	0.09	-67.72	-60.79	0.0049
1	2	0	0	0	1	4	4.37	2.09	18.89	1.37	0.09	-65.79	-55.39	0.0049
1	2	0	1	1	1	5	4.25	2.06	24.07	1.50	0.12	-44.52	-30.74	0.0049
1	2	0	0	1	2	5	4.26	2.06	24.08	1.50	0.12	-44.41	-30.63	0.0048
1	2	1	0	2	1	12	4.35	2.09	21.25	1.46	0.10	84.66	98.11	0.0046
1	2	0	2	0	1	8	4.40	2.10	19.12	1.38	0.09	-64.38	-47.03	0.0045
2	2	1	0	2	1	8	4.36	2.09	21.22	1.46	0.09	38.75	55.74	0.0044
1	2	0	0	0	2	8	4.42	2.10	19.12	1.38	0.08	-64.08	-50.20	0.0043
1	2	0	1	1	1	12	4.32	2.08	24.82	1.53	0.10	-31.79	-18.12	0.0041
0	1	1	0	2	1	3	4.43	2.11	19.60	1.40	0.08	18.20	28.54	0.0040
2	2	0	0	2	2	8	4.39	2.10	22.46	1.50	0.09	-8.07	8.92	0.0039
2	2	0	1	1	2	10	4.46	2.11	19.13	1.38	0.07	-58.03	-37.48	0.0039
0	2	0	1	0	1	11	4.49	2.12	18.76	1.37	0.07	-48.98	-38.57	0.0036
0	2	0	0	1	1	3	4.48	2.12	19.33	1.39	0.07	-35.90	-28.99	0.0036
1	2	0	2	1	2	5	4.43	2.10	24.78	1.54	0.08	-41.99	-21.31	0.0033
0	2	0	1	1	2	6	4.52	2.13	19.06	1.38	0.06	-24.74	-10.97	0.0032
1	2	0	2	0	0	8	4.52	2.12	19.32	1.39	0.06	-64.14	-50.27	0.0032
1	2	0	1	1	1	8	4.45	2.11	23.97	1.52	0.08	-37.89	-24.16	0.0032
1	2	0	1	0	1	5	4.53	2.13	19.06	1.39	0.06	-65.22	-51.35	0.0031
2	2	0	1	2	2	8	4.49	2.12	22.98	1.51	0.07	-6.40	13.99	0.0030
1	2	0	0	1	2	8	4.47	2.11	24.10	1.52	0.07	-37.89	-24.15	0.0030
1	2	0	0	1	2	12	4.47	2.11	25.35	1.56	0.07	-32.29	-18.62	0.0028
1	2	0	0	1	1	8	4.49	2.12	24.40	1.53	0.07	-39.69	-29.39	0.0028
0	2	0	1	0	2	11	4.58	2.14	18.93	1.39	0.05	-47.13	-33.26	0.0026
1	2	0	2	1	1	4	4.51	2.12	24.24	1.53	0.06	-44.74	-27.48	0.0026
1	2	0	0	1	2	4	4.53	2.13	24.33	1.53	0.06	-46.73	-32.93	0.0025
1	2	0	1	1	1	4	4.53	2.13	24.36	1.53	0.06	-46.73	-32.93	0.0024
0	2	0	0	1	2	10	4.59	2.14	19.62	1.41	0.05	-15.12	-4.85	0.0024
0	2	0	2	0	1	11	4.60	2.14	18.97	1.39	0.04	-47.19	-33.32	0.0023
0	1	0	0	2	1	8	4.61	2.15	20.03	1.43	0.04	42.50	49.31	0.0021
2	2	0	2	2	2	8	4.58	2.14	23.31	1.53	0.05	-4.46	19.32	0.0021
2	1	0	2	2	0	12	4.58	2.14	24.63	1.58	0.05	70.33	87.16	0.0020
0	2	1	0	2	1	7	4.61	2.15	21.29	1.48	0.04	54.12	64.35	0.0019

1	2	0	0	1	1	4	4.59	2.14	24.60	1.55	0.05	-48.73	-38.38	0.0019
0	1	0	1	2	0	11	4.62	2.15	23.32	1.54	0.04	158.02	164.77	0.0017
0	2	0	2	1	1	3	4.71	2.17	19.74	1.43	0.02	-32.66	-18.84	0.0011
2	2	0	2	1	1	7	4.71	2.17	20.15	1.44	0.02	-65.37	-44.75	0.0011
1	2	1	0	2	1	8	4.69	2.17	24.20	1.54	0.02	46.12	59.71	0.0010
0	1	0	2	2	0	12	4.70	2.17	25.70	1.62	0.02	93.60	103.70	0.0009
1	1	0	0	2	1	2	4.70	2.17	25.90	1.59	0.02	49.74	60.11	0.0009
1	2	0	1	1	2	12	4.72	2.17	26.37	1.61	0.02	-30.75	-13.67	0.0008
2	2	0	1	1	1	4	4.76	2.18	19.91	1.44	0.01	-79.45	-62.19	0.0006
2	2	0	1	2	2	10	4.75	2.18	23.68	1.54	0.01	18.03	38.31	0.0005
1	2	0	0	1	1	12	4.75	2.18	26.82	1.62	0.01	-31.81	-21.56	0.0005
0	2	1	0	2	1	12	4.77	2.18	21.34	1.49	0.01	103.79	113.87	0.0004
2	2	0	0	2	2	3	4.77	2.18	22.45	1.54	0.01	-50.73	-33.52	0.0004
1	2	1	0	2	1	3	4.77	2.18	23.71	1.53	0.01	37.11	50.88	0.0004
0	2	0	0	0	2	11	4.80	2.19	19.52	1.43	0.00	-49.02	-38.62	0.0002
2	2	0	2	2	2	4	4.80	2.19	24.74	1.57	0.00	-34.83	-10.80	0.0001
1	2	0	2	2	2	3	4.81	2.19	23.50	1.54	0.00	-13.61	7.05	0.0001
2	2	0	1	1	1	12	4.81	2.19	19.74	1.43	0.00	-65.07	-47.99	0.0001
0	2	0	1	1	1	10	4.81	2.19	20.10	1.45	0.00	-15.32	-5.05	0.0001
2	2	0	0	2	2	6	4.81	2.19	20.29	1.45	0.00	-22.64	-5.56	0.0001
1	2	0	1	0	0	6	4.81	2.19	19.82	1.44	0.00	-65.97	-55.57	0.0000
0	2	0	2	1	1	10	4.82	2.19	20.14	1.45	0.00	-13.35	0.35	0.0000
1	2	0	1	2	2	6	4.82	2.19	21.02	1.49	0.00	10.09	27.17	0.0000

Parâmetros dentro dos critérios para a soja utilizando o SARIMA.

p	d	q	P	D	Q	S	mse	rmse	mape	mae	r2	aic	bic	r2/MAPE
2	2	1	0	2	1	9	162,300	403	15	345	0.773	2,573	2,590	0.053
2	2	0	2	1	0	7	160,522	401	15	344	0.776	2,609	2,627	0.053
2	2	1	1	2	1	7	167,783	410	15	348	0.766	2,542	2,563	0.052
1	2	1	1	2	1	7	168,761	411	15	348	0.764	2,541	2,558	0.052
2	2	0	2	2	1	10	182,881	428	14	340	0.745	2,510	2,530	0.052
0	2	1	1	2	1	7	158,989	399	15	344	0.778	2,545	2,558	0.052
1	2	1	0	2	1	9	156,992	396	15	344	0.781	2,574	2,588	0.052
2	2	1	0	2	1	10	167,323	409	15	333	0.766	2,573	2,589	0.052
0	2	0	0	1	0	10	167,578	409	15	343	0.766	2,761	2,765	0.052
0	2	1	0	2	1	10	168,138	410	15	334	0.765	2,576	2,586	0.052
1	2	1	0	2	1	10	168,557	411	15	334	0.765	2,574	2,587	0.051
2	2	1	2	2	1	4	165,668	407	15	350	0.769	2,590	2,614	0.051
1	2	1	2	2	1	4	165,896	407	15	350	0.768	2,588	2,609	0.051
2	2	0	2	1	0	10	197,887	445	14	361	0.724	2,565	2,582	0.051
2	1	0	1	2	0	11	209,916	458	14	364	0.707	2,593	2,607	0.051
1	1	0	1	2	0	11	211,887	460	14	365	0.704	2,592	2,602	0.051
1	2	1	0	2	1	7	165,792	407	15	344	0.768	2,595	2,609	0.051

2	2	1	0	2	1	7	166,017	407	15	344	0.768	2,597	2,614	0.051
0	2	1	2	2	1	4	158,526	398	15	344	0.779	2,589	2,606	0.051
1	2	1	2	2	1	2	160,662	401	15	348	0.776	2,616	2,637	0.051
2	2	1	1	2	1	6	166,926	409	15	341	0.767	2,577	2,597	0.050
2	2	1	0	2	1	8	168,330	410	15	338	0.765	2,638	2,655	0.050
0	2	1	2	2	2	7	175,223	419	15	357	0.755	2,599	2,620	0.050
1	2	1	1	2	1	6	168,565	411	15	341	0.765	2,575	2,592	0.050
1	2	1	0	2	1	8	170,606	413	15	338	0.762	2,636	2,650	0.050
1	2	1	2	2	1	3	165,232	406	15	342	0.769	2,604	2,624	0.050
1	2	0	2	1	0	5	157,328	397	16	343	0.780	2,652	2,665	0.050
2	2	1	2	2	1	5	165,755	407	16	343	0.769	2,558	2,582	0.049
2	2	1	2	2	1	3	168,657	411	16	343	0.764	2,605	2,629	0.049
1	2	1	2	2	1	5	166,490	408	16	343	0.767	2,556	2,577	0.049
2	2	1	2	2	2	6	172,398	415	16	343	0.759	2,585	2,613	0.049
2	2	1	1	2	1	4	166,781	408	16	346	0.767	2,633	2,654	0.048
2	2	1	0	2	1	3	164,678	406	16	355	0.770	2,672	2,690	0.048
1	2	0	2	2	2	2	181,259	426	15	367	0.747	2,592	2,612	0.048
0	2	1	2	2	1	5	170,482	413	16	344	0.762	2,555	2,573	0.048
1	2	1	1	2	1	4	169,504	412	16	347	0.763	2,631	2,649	0.048
0	1	0	1	2	1	4	159,378	399	16	353	0.777	2,632	2,642	0.047
1	1	0	0	2	1	6	162,203	403	16	348	0.773	2,626	2,637	0.047
2	1	0	0	2	1	6	162,795	403	16	349	0.773	2,627	2,641	0.047
2	1	0	1	2	1	5	158,140	398	17	347	0.779	2,605	2,622	0.047
1	1	0	1	2	1	5	158,191	398	17	347	0.779	2,604	2,617	0.047
0	1	1	0	2	1	6	162,164	403	16	347	0.774	2,627	2,637	0.047
0	2	1	0	2	1	3	166,561	408	16	353	0.767	2,674	2,684	0.047
0	1	1	1	2	1	5	158,481	398	17	347	0.779	2,604	2,618	0.047
1	1	0	0	1	0	6	164,374	405	16	353	0.770	2,666	2,673	0.047
0	2	1	1	2	1	6	184,825	430	16	348	0.742	2,577	2,591	0.047
0	2	1	1	2	1	8	213,044	462	15	381	0.702	2,531	2,545	0.047
0	1	0	2	2	1	3	168,093	410	16	363	0.765	2,608	2,622	0.047
0	2	1	0	2	1	12	204,745	452	15	384	0.714	2,514	2,524	0.047
0	1	0	1	2	1	3	161,170	401	17	355	0.775	2,620	2,630	0.047
2	1	0	0	1	0	6	165,720	407	16	355	0.769	2,666	2,676	0.047
0	1	0	1	1	0	5	162,657	403	17	356	0.773	2,633	2,640	0.047
1	2	1	1	2	1	8	216,199	465	15	383	0.698	2,532	2,549	0.046
0	1	0	1	2	1	5	160,666	401	17	347	0.776	2,606	2,616	0.046
0	1	0	0	1	0	6	162,152	403	17	348	0.774	2,669	2,673	0.046
1	1	0	1	1	0	5	166,222	408	17	361	0.768	2,630	2,641	0.046
2	1	0	1	1	0	5	166,504	408	17	362	0.767	2,632	2,645	0.046
0	2	1	1	2	1	2	187,681	433	16	378	0.738	2,636	2,650	0.046
1	1	1	0	2	1	4	166,331	408	17	361	0.768	2,627	2,641	0.046
1	1	1	0	2	1	8	189,839	436	16	378	0.735	2,625	2,639	0.046
0	1	0	0	2	1	8	192,067	438	16	379	0.732	2,640	2,646	0.045
0	1	0	0	2	1	6	167,071	409	17	350	0.767	2,630	2,637	0.045

0	1	0	1	1	0	3	171,158	414	17	368	0.761	2,633	2,640	0.045
1	2	0	0	2	1	10	207,377	455	16	385	0.710	2,624	2,634	0.045
0	2	1	2	2	2	6	191,375	437	16	354	0.733	2,586	2,607	0.045
0	1	0	0	2	1	9	192,881	439	16	382	0.731	2,593	2,600	0.045
2	0	0	1	2	0	8	183,828	429	17	377	0.743	2,679	2,693	0.045
2	2	2	2	2	2	8	226,709	476	15	392	0.683	2,536	2,566	0.045
0	1	1	0	2	1	4	176,090	420	17	376	0.754	2,652	2,662	0.045
2	1	0	0	2	1	4	176,689	420	17	376	0.753	2,654	2,668	0.045
0	1	0	0	1	0	4	165,030	406	17	356	0.770	2,677	2,681	0.045
2	2	0	2	2	1	8	264,389	514	14	394	0.631	2,548	2,568	0.045
0	1	0	1	1	0	4	176,684	420	17	376	0.753	2,652	2,659	0.045
1	1	0	0	2	1	4	178,818	423	17	378	0.750	2,652	2,662	0.044
0	1	0	2	2	1	2	185,364	431	17	383	0.741	2,613	2,627	0.044
1	2	1	0	2	1	4	181,975	427	17	359	0.746	2,654	2,668	0.044
1	1	1	0	2	1	6	171,764	414	17	353	0.760	2,614	2,628	0.044
1	2	1	1	2	2	4	182,200	427	17	359	0.746	2,658	2,679	0.044
2	1	1	1	2	1	3	187,260	433	17	384	0.738	2,618	2,638	0.044
0	1	1	1	2	1	3	187,817	433	17	384	0.738	2,617	2,631	0.044
2	0	0	2	2	0	5	186,963	432	17	372	0.739	2,667	2,685	0.044
0	1	0	0	2	1	7	197,467	444	17	388	0.724	2,611	2,618	0.044
1	2	1	0	2	1	12	229,150	479	16	402	0.680	2,513	2,526	0.044
0	1	0	2	1	0	3	189,036	435	17	387	0.736	2,620	2,630	0.044
0	2	1	0	2	1	9	201,288	449	17	358	0.719	2,593	2,604	0.044
1	2	0	2	2	1	5	198,057	445	17	356	0.723	2,628	2,645	0.043
0	1	0	1	2	0	11	259,881	510	15	377	0.637	2,605	2,612	0.043
0	1	1	1	2	1	4	198,666	446	17	394	0.723	2,629	2,643	0.043
1	1	1	2	2	2	6	210,481	459	16	398	0.706	2,584	2,608	0.043
2	2	1	0	2	1	12	233,539	483	16	406	0.674	2,515	2,531	0.043
0	1	0	0	2	1	4	177,230	421	18	359	0.752	2,654	2,661	0.043
1	0	0	1	2	0	8	185,151	430	17	362	0.741	2,680	2,690	0.043
2	0	0	2	2	0	6	211,157	460	17	384	0.705	2,640	2,657	0.043
2	2	1	1	2	1	3	205,596	453	17	362	0.713	2,622	2,643	0.043
2	1	0	2	2	0	10	278,579	528	14	399	0.611	2,573	2,590	0.042
1	1	0	1	2	1	3	201,673	449	17	398	0.718	2,617	2,631	0.042
1	1	0	1	2	1	4	207,658	456	17	401	0.710	2,629	2,642	0.042
2	1	0	1	2	1	4	210,217	458	17	403	0.706	2,631	2,648	0.042
2	0	0	1	2	0	5	184,012	429	18	358	0.743	2,759	2,773	0.042
2	1	0	1	2	1	3	209,206	457	17	404	0.708	2,619	2,636	0.041
2	1	1	1	2	1	4	214,173	463	17	406	0.701	2,633	2,653	0.041
0	1	0	0	1	0	7	215,650	464	17	404	0.699	2,658	2,662	0.041
1	1	0	2	2	0	10	284,998	534	15	405	0.602	2,573	2,586	0.041
0	1	0	2	1	0	2	207,886	456	17	405	0.710	2,619	2,629	0.041
2	2	0	2	2	0	7	185,865	431	18	365	0.740	2,663	2,680	0.041
0	1	1	0	2	1	8	232,387	482	17	408	0.675	2,636	2,646	0.041
1	2	1	1	2	1	3	218,690	468	17	369	0.695	2,621	2,638	0.041

0	1	0	0	1	0	8	227,164	477	17	410	0.683	2,697	2,700	0.041
0	2	1	0	2	1	8	223,405	473	17	372	0.688	2,640	2,650	0.040
1	0	0	2	2	0	5	202,586	450	18	365	0.717	2,668	2,682	0.040
1	2	0	0	1	0	10	242,900	493	16	414	0.661	2,700	2,707	0.040
2	0	0	2	2	0	10	291,624	540	15	411	0.593	2,587	2,604	0.040
0	2	1	2	2	1	2	218,907	468	17	371	0.694	2,618	2,636	0.040
0	1	0	0	1	0	9	228,143	478	17	415	0.681	2,658	2,661	0.040
2	1	0	0	1	0	4	211,597	460	18	411	0.704	2,678	2,688	0.040
0	2	1	2	2	1	7	262,990	513	16	419	0.633	2,534	2,551	0.040
1	1	0	1	1	0	3	221,630	471	17	415	0.690	2,630	2,640	0.040
0	1	1	2	2	1	3	233,110	483	17	418	0.674	2,599	2,617	0.040
1	1	0	0	2	1	8	243,104	493	17	416	0.660	2,636	2,646	0.040
2	1	1	0	2	1	8	242,970	493	17	416	0.661	2,639	2,656	0.040
1	1	0	0	1	0	4	215,698	464	18	414	0.699	2,676	2,682	0.040
0	1	0	0	2	1	3	218,288	467	18	415	0.695	2,670	2,677	0.039
1	1	1	0	2	1	10	247,893	498	17	419	0.654	2,566	2,580	0.039
2	1	1	0	2	1	10	250,092	500	17	420	0.651	2,575	2,591	0.039
2	1	0	0	2	1	8	247,054	497	17	419	0.655	2,637	2,651	0.039
2	1	0	2	2	1	3	238,076	488	17	421	0.668	2,601	2,622	0.039
2	1	0	1	1	0	3	229,235	479	17	420	0.680	2,632	2,646	0.039
1	1	1	2	2	1	3	241,961	492	17	424	0.662	2,601	2,622	0.039
2	2	1	0	2	1	2	250,593	501	17	424	0.650	2,637	2,654	0.039
0	1	0	2	2	1	5	243,443	493	17	425	0.660	2,552	2,566	0.039
1	2	1	0	2	1	3	247,002	497	17	425	0.655	2,672	2,686	0.038
2	1	0	0	2	1	10	259,725	510	17	425	0.637	2,573	2,586	0.038
2	2	2	1	2	2	4	223,836	473	18	383	0.687	2,635	2,662	0.038
0	1	1	0	2	1	10	260,117	510	17	426	0.637	2,574	2,584	0.038
1	1	0	0	2	1	10	260,153	510	17	426	0.637	2,573	2,584	0.038
2	1	1	0	2	1	9	254,643	505	17	429	0.644	2,577	2,594	0.038
1	1	1	1	2	1	6	250,226	500	17	428	0.651	2,565	2,582	0.038
1	1	0	2	2	1	3	247,450	497	17	428	0.654	2,600	2,617	0.038
0	1	0	0	2	1	10	261,515	511	17	426	0.635	2,576	2,583	0.038
1	1	0	2	2	1	5	249,825	500	17	428	0.651	2,553	2,570	0.038
0	1	0	1	2	1	6	252,392	502	17	429	0.648	2,575	2,585	0.038
0	1	1	2	2	1	5	250,884	501	17	429	0.650	2,553	2,570	0.038
1	1	1	2	2	1	5	251,203	501	17	429	0.649	2,553	2,573	0.038
2	2	0	2	2	1	7	267,343	517	17	382	0.627	2,572	2,592	0.038
2	1	0	2	2	1	5	252,436	502	17	430	0.647	2,555	2,575	0.038
2	1	1	2	2	1	5	252,762	503	17	430	0.647	2,555	2,579	0.038
0	1	0	2	2	1	4	261,031	511	17	435	0.635	2,585	2,599	0.037
1	1	0	1	1	0	4	252,691	503	18	435	0.647	2,649	2,660	0.037
1	1	0	0	2	1	9	267,348	517	17	437	0.627	2,574	2,585	0.037
2	0	0	2	2	0	3	255,657	506	18	425	0.643	2,690	2,708	0.037
2	1	0	1	1	0	4	256,154	506	18	437	0.642	2,651	2,665	0.036
0	1	0	2	2	0	10	316,470	563	15	432	0.558	2,576	2,587	0.036

1	0	0	1	2	0	7	259,185	509	18	418	0.638	2,682	2,692	0.036
2	1	0	0	2	1	3	253,616	504	18	439	0.646	2,669	2,683	0.036
1	0	0	2	2	0	4	224,640	474	19	408	0.686	2,716	2,730	0.036
2	0	0	1	2	0	6	233,829	484	19	410	0.673	2,723	2,737	0.036
0	1	1	1	2	1	6	276,995	526	17	443	0.613	2,574	2,587	0.035
1	0	0	2	2	0	10	323,556	569	16	438	0.548	2,591	2,604	0.035
2	0	0	1	2	0	3	233,094	483	19	410	0.674	2,741	2,755	0.035
0	2	0	0	2	1	10	283,583	533	17	394	0.604	2,682	2,689	0.035
1	1	0	1	2	1	6	281,898	531	17	446	0.606	2,573	2,587	0.035
2	1	0	2	1	0	3	275,035	524	18	448	0.616	2,612	2,630	0.035
2	0	1	2	2	1	5	276,394	526	18	447	0.614	2,565	2,589	0.035
0	1	0	0	1	0	3	259,725	510	18	447	0.637	2,687	2,690	0.035
2	1	0	1	2	1	6	286,593	535	17	449	0.600	2,575	2,592	0.034
1	1	0	0	1	0	8	286,923	536	18	450	0.599	2,693	2,700	0.034
1	1	1	2	2	1	4	290,202	539	18	452	0.595	2,571	2,592	0.034
1	1	0	2	1	0	3	283,407	532	18	453	0.604	2,611	2,625	0.034
1	1	0	2	2	1	2	282,977	532	18	453	0.605	2,611	2,628	0.034
0	1	0	1	1	0	6	288,577	537	18	453	0.597	2,608	2,615	0.034
2	1	0	0	1	0	8	291,510	540	18	453	0.593	2,695	2,705	0.034
0	1	1	2	2	1	2	286,751	535	18	455	0.600	2,611	2,628	0.034
1	1	0	0	1	0	10	308,933	556	17	457	0.569	2,647	2,654	0.033
2	1	0	0	1	0	10	308,980	556	17	457	0.568	2,646	2,656	0.033
0	1	1	0	2	1	7	301,558	549	18	460	0.579	2,595	2,605	0.032
0	1	0	2	2	0	9	347,086	589	16	445	0.515	2,597	2,607	0.032
1	2	1	2	2	1	7	327,166	572	17	459	0.543	2,529	2,549	0.032
2	2	1	2	2	1	7	327,210	572	17	459	0.543	2,531	2,555	0.032
0	1	0	0	1	0	10	310,418	557	17	458	0.566	2,649	2,653	0.032
0	0	0	2	2	0	4	280,130	529	19	444	0.609	2,921	2,932	0.032
2	1	0	0	2	1	9	310,749	557	18	463	0.566	2,573	2,586	0.032
0	2	1	0	2	1	7	285,259	534	19	413	0.602	2,612	2,622	0.032
2	0	0	2	2	1	5	302,222	550	18	463	0.578	2,561	2,582	0.032
1	0	0	0	2	0	12	272,472	522	19	430	0.619	2,700	2,707	0.032
0	1	0	2	1	0	5	303,214	551	18	463	0.577	2,574	2,584	0.032
1	0	1	2	2	1	5	303,055	551	18	463	0.577	2,561	2,582	0.032
0	1	1	2	2	1	4	314,574	561	18	465	0.561	2,584	2,601	0.032
1	1	1	0	2	1	9	317,691	564	18	467	0.556	2,571	2,584	0.032
1	0	0	2	2	0	9	354,457	595	16	450	0.505	2,611	2,625	0.032
0	1	0	1	2	1	2	303,536	551	18	467	0.576	2,631	2,642	0.031
2	1	0	2	2	1	4	316,241	562	18	466	0.558	2,586	2,607	0.031
1	1	0	2	2	1	4	317,725	564	18	466	0.556	2,584	2,601	0.031
2	1	0	0	1	0	3	296,437	544	19	469	0.586	2,686	2,696	0.031
1	1	0	0	1	0	9	314,930	561	18	469	0.560	2,638	2,645	0.031
1	1	0	2	1	0	5	311,332	558	18	467	0.565	2,575	2,588	0.031
1	0	0	0	2	0	8	294,204	542	19	448	0.589	2,870	2,877	0.031
2	1	0	2	1	0	5	314,043	560	18	469	0.561	2,576	2,594	0.031

0	2	1	2	2	1	3	290,963	539	19	420	0.594	2,613	2,630	0.031
1	1	0	1	1	0	6	319,756	565	18	470	0.553	2,606	2,617	0.031
1	1	0	2	1	0	2	312,038	559	18	472	0.564	2,617	2,631	0.031
0	1	1	0	2	1	9	326,029	571	18	472	0.545	2,569	2,579	0.031
1	1	0	1	2	0	3	267,616	517	20	434	0.626	2,773	2,784	0.031
0	1	0	2	1	0	4	318,221	564	18	472	0.556	2,602	2,612	0.031
2	1	0	1	1	0	6	323,913	569	18	472	0.548	2,608	2,622	0.030
1	0	0	0	2	0	10	334,090	578	18	448	0.533	2,787	2,794	0.030
2	1	1	0	2	1	7	325,985	571	18	476	0.545	2,598	2,615	0.030
1	0	0	2	2	0	2	274,248	524	21	451	0.617	2,688	2,702	0.030
0	0	0	1	2	0	5	315,283	562	19	454	0.560	3,037	3,044	0.030
1	1	1	0	2	1	7	334,938	579	18	481	0.532	2,597	2,610	0.029
0	1	0	1	2	1	7	340,199	583	18	481	0.525	2,543	2,553	0.029
0	2	1	1	2	2	4	297,119	545	20	436	0.585	2,660	2,677	0.029
1	1	1	2	2	1	2	335,213	579	18	483	0.532	2,589	2,609	0.029
2	1	0	0	2	1	7	339,209	582	18	484	0.526	2,597	2,610	0.029
2	0	0	2	2	0	4	338,436	582	18	473	0.527	2,703	2,720	0.029
0	2	1	1	2	1	4	305,720	553	20	436	0.573	2,635	2,648	0.029
1	1	0	0	2	1	7	342,386	585	18	485	0.522	2,595	2,605	0.028
2	0	0	0	2	0	12	334,717	579	19	466	0.533	2,698	2,708	0.028
2	1	0	0	1	0	7	352,389	594	19	491	0.508	2,644	2,654	0.027
1	1	0	0	1	0	7	355,283	596	19	493	0.504	2,642	2,648	0.027
2	1	0	0	1	0	9	359,959	600	18	495	0.497	2,637	2,647	0.027
1	0	0	2	2	0	3	301,294	549	22	447	0.579	2,718	2,732	0.027
2	2	0	2	2	2	3	373,784	611	18	492	0.478	2,574	2,598	0.027
2	0	0	0	2	0	9	359,675	600	19	473	0.498	2,770	2,780	0.027
1	2	0	2	1	1	2	358,976	599	19	497	0.499	2,585	2,603	0.027
0	1	0	1	1	0	2	355,162	596	19	502	0.504	2,639	2,646	0.026
1	1	1	1	2	1	7	373,885	611	18	499	0.478	2,541	2,558	0.026
0	1	1	0	2	1	3	360,135	600	19	503	0.497	2,669	2,679	0.026
0	2	1	1	2	1	10	391,188	625	18	496	0.454	2,513	2,526	0.026
1	0	1	2	2	1	4	372,826	611	19	504	0.479	2,592	2,613	0.025
2	1	0	0	1	0	5	306,410	554	23	466	0.572	2,682	2,692	0.025
2	1	0	2	1	0	4	378,501	615	19	507	0.471	2,603	2,621	0.025
1	1	0	2	1	0	4	380,126	617	19	508	0.469	2,601	2,615	0.025
1	1	0	0	1	0	5	311,098	558	23	470	0.566	2,680	2,687	0.025
2	2	0	1	2	0	11	403,825	635	18	500	0.436	2,615	2,628	0.024
0	1	0	1	1	0	7	387,259	622	19	511	0.459	2,582	2,589	0.024
1	1	1	0	2	1	3	381,240	617	20	516	0.468	2,671	2,685	0.024
2	1	0	0	2	1	2	385,461	621	19	516	0.462	2,632	2,646	0.024
2	2	1	1	2	1	10	413,301	643	18	507	0.423	2,509	2,530	0.024
2	1	0	1	2	1	7	400,565	633	19	516	0.441	2,540	2,558	0.023
0	1	1	1	2	1	7	402,379	634	19	517	0.438	2,538	2,552	0.023
1	2	1	1	2	1	10	417,135	646	18	509	0.417	2,508	2,524	0.023
1	0	0	0	2	0	7	367,222	606	21	493	0.487	2,832	2,839	0.023

1	1	0	1	2	1	7	405,674	637	19	519	0.433	2,539	2,552	0.023
0	2	1	0	2	1	11	421,504	649	18	515	0.411	2,512	2,522	0.023
1	1	0	0	2	1	3	397,220	630	20	525	0.445	2,669	2,679	0.023
2	1	1	1	2	1	7	414,789	644	19	524	0.421	2,540	2,561	0.022
1	2	0	2	0	0	2	408,264	639	20	529	0.430	2,594	2,608	0.022
2	2	0	2	0	0	3	413,029	643	19	529	0.423	2,591	2,609	0.022
0	2	1	1	2	1	3	378,069	615	22	486	0.472	2,624	2,638	0.022
2	0	0	1	2	0	4	392,025	626	21	502	0.453	2,761	2,775	0.022
0	2	1	2	2	1	6	436,324	661	18	518	0.391	2,546	2,563	0.022
1	2	1	1	2	1	2	418,424	647	19	527	0.416	2,636	2,653	0.022
2	2	0	1	2	2	3	427,568	654	19	526	0.403	2,578	2,598	0.021
0	1	0	0	1	0	5	357,258	598	24	508	0.501	2,681	2,685	0.020
0	1	0	0	2	1	12	443,847	666	19	535	0.380	2,514	2,521	0.020
2	0	1	1	2	1	7	440,363	664	20	542	0.385	2,550	2,571	0.020
2	1	0	1	1	0	7	442,845	665	20	543	0.382	2,580	2,593	0.019
2	2	1	1	2	1	5	402,896	635	23	509	0.437	2,607	2,628	0.019
1	1	0	1	1	0	7	447,035	669	20	545	0.376	2,578	2,588	0.019
2	1	0	0	1	0	2	439,365	663	20	551	0.386	2,639	2,650	0.019
0	0	0	2	2	0	3	387,203	622	24	527	0.459	2,907	2,917	0.019
1	1	1	1	2	1	8	454,892	674	19	545	0.365	2,533	2,550	0.019
2	0	0	0	2	0	6	420,451	648	22	507	0.413	2,828	2,838	0.019
1	0	0	1	2	0	3	390,028	625	24	525	0.455	2,752	2,763	0.019
0	1	0	1	2	1	8	457,394	676	19	546	0.361	2,529	2,539	0.019
1	2	1	1	2	1	5	412,859	643	23	515	0.423	2,606	2,623	0.018
2	1	1	1	2	1	8	460,508	679	19	548	0.357	2,524	2,544	0.018
1	1	0	1	2	1	8	461,532	679	19	548	0.355	2,530	2,544	0.018
1	1	0	0	1	0	3	449,622	671	21	557	0.372	2,685	2,692	0.018
0	1	1	1	2	1	8	464,907	682	20	550	0.351	2,530	2,543	0.018
0	2	1	0	2	1	4	415,805	645	23	521	0.419	2,656	2,667	0.018
0	1	1	0	2	1	12	475,018	689	19	550	0.337	2,513	2,523	0.017
2	1	0	2	2	0	9	488,780	699	18	531	0.317	2,587	2,604	0.017
1	1	0	0	2	1	12	479,782	693	19	553	0.330	2,513	2,523	0.017
2	2	0	2	1	1	3	474,151	689	20	560	0.338	2,572	2,593	0.017
2	1	0	0	2	1	12	484,202	696	20	555	0.324	2,515	2,528	0.017
1	0	0	0	2	0	9	420,125	648	25	548	0.413	2,813	2,820	0.016
0	1	0	0	1	0	12	483,679	695	20	559	0.325	2,604	2,607	0.016
1	1	0	2	2	0	9	499,180	707	19	537	0.303	2,589	2,602	0.016
2	1	0	1	2	1	8	488,164	699	20	563	0.318	2,531	2,548	0.016
0	0	0	0	2	0	5	447,120	669	24	539	0.376	3,073	3,076	0.016
0	1	1	0	2	1	5	424,334	651	26	554	0.407	2,648	2,658	0.016
2	1	1	0	2	1	5	425,841	653	26	555	0.405	2,652	2,669	0.016
2	1	0	0	2	1	5	426,039	653	26	555	0.405	2,650	2,664	0.016
1	1	1	0	2	1	5	426,321	653	26	555	0.405	2,649	2,663	0.016
1	1	0	0	2	1	5	434,943	660	26	561	0.393	2,648	2,659	0.015
2	0	0	0	2	0	10	507,434	712	20	551	0.291	2,780	2,791	0.015

0	2	1	1	2	1	5	469,613	685	24	553	0.344	2,608	2,622	0.014
1	2	0	1	1	0	8	494,933	704	22	535	0.309	2,660	2,671	0.014
2	2	0	1	0	0	3	508,906	713	21	584	0.289	2,596	2,609	0.014
1	1	0	0	1	0	12	520,502	721	20	575	0.273	2,603	2,610	0.014
2	1	0	0	1	0	12	524,775	724	20	578	0.267	2,605	2,615	0.013
2	0	1	1	2	1	8	522,438	723	21	583	0.270	2,532	2,552	0.013
2	0	0	1	2	1	8	522,938	723	21	584	0.270	2,540	2,557	0.013
0	1	0	1	2	0	12	531,810	729	20	568	0.257	2,603	2,609	0.013
1	0	0	1	2	0	9	528,461	727	21	571	0.262	2,647	2,657	0.013
1	0	1	1	2	1	8	528,480	727	21	587	0.262	2,540	2,557	0.013
0	1	0	1	1	0	8	532,632	730	21	589	0.256	2,574	2,581	0.012
1	1	0	1	1	0	8	537,178	733	21	591	0.250	2,575	2,586	0.012
2	2	1	2	2	1	6	548,205	740	20	582	0.234	2,545	2,569	0.012
1	1	0	1	2	1	2	535,813	732	22	600	0.252	2,631	2,645	0.012
1	0	0	1	2	0	6	497,223	705	26	585	0.306	2,731	2,741	0.012
1	2	1	2	2	1	6	551,765	743	20	584	0.229	2,543	2,563	0.012
0	1	0	0	2	1	5	494,332	703	28	600	0.310	2,650	2,656	0.011
2	2	1	0	2	1	6	521,879	722	25	570	0.271	2,628	2,645	0.011
2	1	0	1	1	0	8	563,570	751	21	604	0.213	2,576	2,590	0.010
2	0	0	0	2	0	3	523,205	723	27	618	0.269	2,817	2,827	0.010
1	2	1	0	2	1	6	544,395	738	25	583	0.240	2,628	2,641	0.010
1	0	0	1	2	0	5	535,111	732	29	627	0.253	2,771	2,782	0.009
0	1	0	2	2	1	7	582,698	763	21	615	0.186	2,531	2,545	0.009
1	0	0	1	2	0	10	587,333	766	21	590	0.180	2,661	2,671	0.009
0	0	0	1	2	0	4	554,247	744	26	613	0.226	2,991	2,998	0.009
1	1	0	1	1	0	2	589,414	768	22	629	0.177	2,638	2,649	0.008
2	2	0	2	1	2	3	611,315	782	22	633	0.146	2,581	2,605	0.007
1	1	1	2	2	1	7	613,665	783	22	629	0.143	2,530	2,550	0.007
2	0	0	1	2	0	7	613,322	783	22	611	0.143	2,670	2,683	0.006
2	2	0	1	1	1	3	625,720	791	22	640	0.126	2,577	2,594	0.006
2	0	0	0	2	0	5	602,878	776	30	649	0.158	2,845	2,855	0.005
1	0	0	1	2	0	4	625,299	791	28	635	0.127	2,779	2,789	0.004
0	2	0	1	2	0	6	612,499	783	33	673	0.145	2,847	2,854	0.004
0	1	0	0	2	0	11	649,171	806	22	571	0.093	2,693	2,697	0.004
0	1	0	2	1	0	7	653,635	808	22	649	0.087	2,567	2,577	0.004
0	1	1	2	2	1	7	660,320	813	22	651	0.078	2,527	2,544	0.003
0	1	0	1	2	0	3	644,822	803	29	661	0.099	2,772	2,779	0.003
0	0	0	1	2	0	3	650,473	807	30	687	0.092	2,911	2,918	0.003
2	1	1	2	2	1	7	670,479	819	22	656	0.064	2,529	2,553	0.003
2	2	0	2	1	0	8	674,878	822	21	637	0.057	2,589	2,606	0.003
0	1	0	0	2	1	11	673,217	820	22	656	0.060	2,512	2,519	0.003
2	1	0	2	2	1	7	673,722	821	23	657	0.059	2,529	2,549	0.003
1	1	0	2	2	1	7	674,095	821	23	658	0.059	2,527	2,544	0.003
1	1	1	1	2	1	10	674,400	821	22	654	0.058	2,508	2,525	0.003
1	1	0	0	2	0	11	676,626	823	23	623	0.055	2,679	2,686	0.002

0	1	0	1	2	1	10	680,789	825	22	657	0.049	2,511	2,522	0.002
0	1	1	1	2	1	2	682,781	826	23	671	0.046	2,630	2,644	0.002
1	0	0	1	2	0	2	677,051	823	28	699	0.054	2,748	2,759	0.002
2	1	0	1	2	1	10	700,559	837	23	666	0.022	2,508	2,525	0.001
1	1	0	1	2	1	10	704,104	839	23	667	0.017	2,507	2,520	0.001
0	1	1	1	2	1	10	705,820	840	23	668	0.014	2,507	2,520	0.001
0	2	1	0	2	1	6	703,557	839	28	666	0.017	2,632	2,642	0.001
2	0	0	0	2	0	4	706,134	840	28	666	0.014	2,818	2,828	0.000
0	2	1	1	2	1	9	708,514	842	22	664	0.011	2,514	2,527	0.000
0	2	1	1	2	1	11	709,874	843	22	663	0.009	2,485	2,498	0.000
2	0	0	2	2	0	7	715,064	846	23	663	0.001	2,617	2,634	0.000

Parâmetros dentro dos critérios para a café utilizando o SARIMA.

p	d	q	P	D	Q	S	mse	rmse	mape	mae	r2	aic	bic	r2/MAPE
1	2	1	2	2	1	3	14.16	3.76	13.94	2.84	0.74	392.82	413.48	0.053
0	2	1	1	2	1	4	14.00	3.74	14.12	2.85	0.74	412.26	425.99	0.052
2	2	0	0	2	2	10	13.57	3.68	14.31	2.84	0.75	422.36	439.26	0.052
1	2	0	0	2	2	10	13.91	3.73	14.22	2.87	0.74	425.91	439.43	0.052
0	2	1	2	2	1	3	15.07	3.88	13.82	2.93	0.72	396.23	413.45	0.052
0	2	1	0	2	1	6	14.87	3.86	13.98	2.90	0.72	472.63	482.88	0.052
2	2	1	1	2	1	4	13.90	3.73	14.48	2.86	0.74	404.57	425.17	0.051
2	2	1	2	2	1	3	14.33	3.79	14.46	2.86	0.73	393.92	418.01	0.051
0	2	0	2	0	2	4	14.44	3.80	14.52	2.86	0.73	412.58	429.92	0.050
0	2	0	1	1	1	3	14.12	3.76	14.65	2.90	0.74	419.59	429.96	0.050
0	2	0	0	1	2	3	14.34	3.79	14.64	2.92	0.73	419.94	430.31	0.050
0	2	0	0	1	1	4	13.70	3.70	14.91	2.90	0.75	424.58	431.48	0.050
0	1	1	1	2	1	3	14.19	3.77	14.74	2.89	0.74	401.68	415.46	0.050
2	2	0	2	1	2	3	14.62	3.82	14.59	2.90	0.73	342.02	366.21	0.050
1	0	0	2	2	0	3	14.65	3.83	14.64	2.92	0.73	485.11	498.91	0.050
0	2	0	0	1	1	8	13.61	3.69	15.03	2.90	0.75	431.68	438.55	0.050
0	2	0	1	1	2	3	13.47	3.67	15.09	2.90	0.75	419.88	433.70	0.050
0	2	0	0	1	2	4	13.60	3.69	15.04	2.91	0.75	426.55	436.91	0.050
1	1	0	1	2	1	3	13.57	3.68	15.07	2.90	0.75	400.57	414.35	0.050
0	2	0	0	1	1	11	14.95	3.87	14.55	2.94	0.72	428.71	435.55	0.050
1	1	0	0	2	1	5	14.14	3.76	14.86	2.92	0.74	479.28	489.57	0.050
0	2	0	1	1	1	4	13.59	3.69	15.08	2.91	0.75	426.55	436.90	0.050
1	1	1	1	2	1	3	13.53	3.68	15.10	2.90	0.75	402.56	419.79	0.050
0	1	0	1	2	1	3	14.90	3.86	14.60	2.91	0.72	408.75	419.09	0.050
2	1	0	1	2	1	3	13.48	3.67	15.16	2.90	0.75	402.55	419.78	0.049
1	0	0	2	2	0	4	16.11	4.01	14.18	2.90	0.70	479.05	492.82	0.049
1	1	1	0	2	1	5	13.71	3.70	15.12	2.92	0.75	480.89	494.61	0.049
0	2	0	0	2	2	10	16.23	4.03	14.21	2.97	0.70	467.28	477.42	0.049
2	1	0	1	1	0	3	14.50	3.81	14.89	2.91	0.73	386.68	400.52	0.049

1	1	0	1	1	0	3	14.63	3.82	14.86	2.91	0.73	384.69	395.06	0.049
0	1	1	0	2	1	5	15.18	3.90	14.66	2.95	0.72	480.89	491.18	0.049
2	2	0	1	1	1	3	13.31	3.65	15.39	2.92	0.75	340.10	357.38	0.049
2	2	0	1	0	0	3	14.21	3.77	15.05	2.91	0.74	327.96	341.83	0.049
2	2	0	0	2	2	11	16.18	4.02	14.32	3.01	0.70	434.90	451.75	0.049
0	1	0	2	1	0	2	13.85	3.72	15.28	2.92	0.74	362.69	373.08	0.049
2	1	2	2	2	2	3	16.13	4.02	14.42	2.95	0.70	366.38	397.40	0.049
0	2	0	1	0	2	5	13.44	3.67	15.46	2.92	0.75	410.92	424.79	0.049
1	2	1	1	2	1	4	14.30	3.78	15.14	2.92	0.73	402.92	420.09	0.049
1	2	1	0	2	1	6	15.61	3.95	14.64	2.92	0.71	463.33	477.00	0.048
2	1	0	0	1	0	5	13.81	3.72	15.35	2.93	0.74	463.65	474.00	0.048
0	2	0	2	1	1	3	13.49	3.67	15.50	2.93	0.75	420.65	434.47	0.048
1	2	0	2	0	0	2	13.70	3.70	15.43	2.93	0.75	330.68	344.55	0.048
0	2	0	1	1	2	4	16.13	4.02	14.50	2.99	0.70	427.01	440.82	0.048
1	2	0	2	0	2	5	14.31	3.78	15.21	2.94	0.73	359.96	380.77	0.048
1	2	0	0	2	2	11	16.27	4.03	14.48	3.03	0.70	438.54	452.02	0.048
0	2	0	1	0	2	6	14.00	3.74	15.37	2.93	0.74	416.04	429.91	0.048
0	2	0	2	0	0	5	13.06	3.61	15.74	2.93	0.76	408.98	419.38	0.048
0	2	0	0	1	1	3	13.55	3.68	15.60	2.94	0.75	420.92	427.83	0.048
0	2	0	1	0	1	4	13.89	3.73	15.49	2.94	0.74	415.27	425.68	0.048
0	2	0	2	1	2	4	16.49	4.06	14.48	3.00	0.69	429.01	446.26	0.048
2	1	1	1	2	1	3	13.28	3.64	15.73	2.94	0.75	403.47	424.15	0.048
1	2	1	0	2	1	8	17.29	4.16	14.23	3.07	0.68	448.65	462.24	0.048
0	1	0	0	2	1	5	16.41	4.05	14.59	2.99	0.70	485.48	492.34	0.048
0	2	0	2	0	0	6	13.86	3.72	15.59	2.95	0.74	414.14	424.55	0.048
0	2	0	0	0	1	6	13.74	3.71	15.65	2.95	0.74	412.17	419.11	0.048
1	1	0	0	1	0	5	15.99	4.00	14.77	2.98	0.70	463.03	469.93	0.048
0	2	0	1	0	1	6	13.69	3.70	15.68	2.95	0.75	414.16	424.57	0.048
0	2	0	0	0	2	6	13.58	3.68	15.73	2.95	0.75	414.14	424.54	0.048
0	2	0	1	0	0	6	13.64	3.69	15.70	2.95	0.75	412.17	419.11	0.048
2	2	0	1	2	2	11	16.56	4.07	14.57	3.06	0.69	436.53	456.75	0.048
0	1	0	1	1	0	3	16.47	4.06	14.62	2.97	0.69	393.02	399.94	0.047
0	1	0	2	2	1	2	13.33	3.65	15.85	2.95	0.75	375.86	389.68	0.047
1	2	0	1	2	2	10	14.41	3.80	15.45	2.92	0.73	425.77	442.67	0.047
1	1	0	2	1	0	2	13.38	3.66	15.88	2.96	0.75	355.03	368.89	0.047
0	2	0	0	0	2	5	13.16	3.63	15.97	2.96	0.76	409.26	419.67	0.047
0	2	0	0	0	2	8	13.69	3.70	15.78	2.96	0.75	411.85	422.25	0.047
0	2	0	2	0	0	3	15.90	3.99	14.92	2.97	0.70	411.52	421.92	0.047
2	2	0	2	2	2	3	17.15	4.14	14.45	3.05	0.68	363.90	387.99	0.047
2	2	1	0	2	1	6	16.08	4.01	14.87	2.94	0.70	465.23	482.31	0.047
1	2	0	2	2	2	10	14.87	3.86	15.37	2.92	0.72	427.52	447.80	0.047
0	2	0	0	0	2	3	16.08	4.01	14.93	2.98	0.70	412.18	422.59	0.047
0	2	0	1	0	2	3	16.08	4.01	14.96	2.98	0.70	412.46	426.34	0.047
0	2	0	2	0	1	5	13.20	3.63	16.10	2.97	0.75	410.93	424.80	0.047
0	2	0	2	0	0	8	14.74	3.84	15.53	2.97	0.73	411.18	421.58	0.047

0	2	0	2	0	1	3	16.29	4.04	14.95	2.99	0.70	412.56	426.43	0.047
0	2	0	1	1	2	9	16.62	4.08	14.85	3.04	0.69	424.44	438.16	0.047
2	1	0	0	2	1	5	13.72	3.70	16.03	2.98	0.75	479.92	493.63	0.046
0	2	0	0	0	2	11	15.03	3.88	15.53	2.98	0.72	412.88	423.29	0.046
0	2	0	1	0	1	8	13.38	3.66	16.26	2.99	0.75	411.91	422.31	0.046
1	1	0	1	2	1	4	17.72	4.21	14.52	3.03	0.67	390.05	403.81	0.046
0	2	0	2	0	2	10	13.45	3.67	16.25	2.99	0.75	411.15	428.49	0.046
0	2	0	1	0	0	4	16.44	4.06	15.09	3.01	0.69	413.71	420.64	0.046
0	2	0	0	0	1	4	16.48	4.06	15.09	3.01	0.69	413.71	420.64	0.046
2	2	1	0	2	1	7	18.68	4.32	14.22	3.17	0.65	480.03	497.06	0.046
1	2	0	2	1	1	2	13.58	3.69	16.31	3.00	0.75	342.08	359.38	0.046
0	2	0	0	0	0	2	16.63	4.08	15.08	3.01	0.69	411.71	415.18	0.046
0	2	0	0	0	0	3	16.63	4.08	15.08	3.01	0.69	411.71	415.18	0.046
0	2	0	0	0	0	4	16.63	4.08	15.08	3.01	0.69	411.71	415.18	0.046
0	2	0	0	0	0	5	16.63	4.08	15.08	3.01	0.69	411.71	415.18	0.046
0	2	0	0	0	0	6	16.63	4.08	15.08	3.01	0.69	411.71	415.18	0.046
0	2	0	0	0	0	7	16.63	4.08	15.08	3.01	0.69	411.71	415.18	0.046
0	2	0	0	0	0	8	16.63	4.08	15.08	3.01	0.69	411.71	415.18	0.046
0	2	0	0	0	0	9	16.63	4.08	15.08	3.01	0.69	411.71	415.18	0.046
0	2	0	0	0	0	10	16.63	4.08	15.08	3.01	0.69	411.71	415.18	0.046
0	2	0	0	0	0	11	16.63	4.08	15.08	3.01	0.69	411.71	415.18	0.046
0	2	0	0	0	0	12	16.63	4.08	15.08	3.01	0.69	411.71	415.18	0.046
0	2	0	1	0	0	7	16.24	4.03	15.25	3.01	0.70	411.98	418.92	0.046
0	2	0	2	0	0	2	16.68	4.08	15.12	3.02	0.69	415.43	425.84	0.046
0	2	0	1	0	2	4	13.43	3.66	16.45	3.01	0.75	413.85	427.73	0.046
0	2	0	0	0	1	8	13.42	3.66	16.46	3.01	0.75	409.93	416.87	0.046
1	2	0	2	0	1	9	14.34	3.79	16.09	3.01	0.73	367.31	384.65	0.046
0	0	0	2	2	0	2	16.93	4.11	15.06	3.04	0.69	565.47	575.85	0.046
0	2	0	1	0	0	2	16.82	4.10	15.12	3.03	0.69	413.44	420.37	0.045
1	2	0	2	0	2	7	14.85	3.85	15.92	3.01	0.72	369.01	389.82	0.045
0	2	0	2	0	0	11	15.98	4.00	15.47	3.02	0.70	413.12	423.53	0.045
0	2	0	0	0	1	2	16.87	4.11	15.12	3.03	0.69	413.44	420.37	0.045
0	2	0	1	0	0	12	16.91	4.11	15.10	3.03	0.69	413.70	420.64	0.045
0	2	0	1	2	2	3	15.85	3.98	15.56	3.00	0.71	448.76	462.53	0.045
0	2	0	0	0	2	2	16.93	4.11	15.12	3.03	0.69	415.44	425.84	0.045
0	1	1	2	2	1	2	13.71	3.70	16.47	3.02	0.75	365.30	382.57	0.045
0	2	0	0	0	1	12	17.03	4.13	15.12	3.04	0.68	413.70	420.64	0.045
0	2	0	0	0	1	10	13.50	3.67	16.58	3.02	0.75	407.62	414.56	0.045
0	2	0	1	0	1	3	17.44	4.18	14.96	3.04	0.68	410.80	421.20	0.045
0	2	0	0	0	1	7	16.62	4.08	15.31	3.03	0.69	411.76	418.70	0.045
0	2	0	0	0	2	4	13.49	3.67	16.60	3.02	0.75	411.92	422.32	0.045
1	2	0	2	1	2	9	14.29	3.78	16.29	3.05	0.73	371.30	391.87	0.045
0	2	0	1	1	2	2	14.11	3.76	16.38	3.03	0.74	424.21	438.05	0.045
0	2	0	1	1	1	9	16.49	4.06	15.43	3.08	0.69	419.53	429.82	0.045
1	1	1	2	2	1	2	13.84	3.72	16.62	3.03	0.74	354.56	375.29	0.045

0	2	0	0	1	2	2	14.24	3.77	16.47	3.04	0.74	422.42	432.80	0.045
0	2	0	0	1	1	2	14.26	3.78	16.49	3.04	0.74	420.78	427.70	0.045
0	2	0	1	0	1	11	16.67	4.08	15.49	3.05	0.69	413.15	423.55	0.045
0	2	0	1	0	0	8	13.60	3.69	16.78	3.04	0.75	410.25	417.18	0.045
0	2	0	1	1	1	2	14.29	3.78	16.51	3.04	0.73	422.42	432.80	0.045
0	2	0	1	0	2	10	13.76	3.71	16.75	3.04	0.74	411.48	425.35	0.044
0	2	0	2	0	1	10	13.76	3.71	16.75	3.04	0.74	411.48	425.35	0.044
0	2	0	1	0	1	10	13.77	3.71	16.76	3.04	0.74	409.48	419.88	0.044
0	2	0	2	0	0	10	13.77	3.71	16.76	3.04	0.74	409.48	419.88	0.044
1	2	0	1	2	2	11	18.22	4.27	14.90	3.15	0.66	439.92	456.78	0.044
0	2	0	1	0	0	10	13.75	3.71	16.77	3.05	0.74	407.48	414.42	0.044
2	2	0	2	0	1	9	13.82	3.72	16.75	3.05	0.74	361.25	382.06	0.044
0	2	0	2	0	1	4	13.65	3.69	16.85	3.05	0.75	414.24	428.11	0.044
1	2	0	1	0	2	9	13.88	3.73	16.76	3.06	0.74	367.87	385.21	0.044
0	2	0	0	0	2	10	13.77	3.71	16.83	3.05	0.74	409.53	419.93	0.044
0	2	0	2	0	2	5	14.32	3.78	16.62	3.05	0.73	410.10	427.44	0.044
0	2	0	2	0	0	4	13.68	3.70	16.89	3.05	0.75	412.24	422.65	0.044
1	1	0	2	2	1	2	14.00	3.74	16.77	3.05	0.74	368.25	385.52	0.044
2	2	0	2	0	2	7	14.28	3.78	16.66	3.07	0.73	362.12	386.39	0.044
0	2	0	1	0	1	2	13.71	3.70	16.91	3.06	0.75	413.90	424.30	0.044
2	2	1	0	2	1	8	19.30	4.39	14.56	3.20	0.64	450.33	467.32	0.044
0	1	0	0	1	0	5	18.46	4.30	14.92	3.12	0.66	469.42	472.87	0.044
0	2	0	1	0	0	11	17.09	4.13	15.52	3.07	0.68	411.16	418.10	0.044
2	2	0	2	1	2	4	14.15	3.76	16.77	3.06	0.74	374.25	398.41	0.044
0	2	0	1	0	2	12	15.78	3.97	16.11	3.03	0.71	409.05	422.92	0.044
1	2	0	2	0	2	9	13.76	3.71	17.00	3.07	0.74	367.89	388.70	0.044
1	1	1	1	2	1	4	19.11	4.37	14.74	3.13	0.65	391.78	408.97	0.044
0	2	0	2	1	1	2	14.55	3.81	16.69	3.06	0.73	424.41	438.25	0.044
1	2	0	2	0	2	3	15.18	3.90	16.43	3.06	0.72	366.27	387.08	0.044
1	2	0	2	1	2	4	14.31	3.78	16.82	3.07	0.73	380.75	401.45	0.044
0	2	0	1	2	1	12	20.19	4.49	14.51	3.35	0.62	537.97	548.06	0.043
0	2	0	0	1	1	9	14.42	3.80	17.01	3.08	0.73	422.61	429.46	0.043
1	2	0	2	1	1	9	14.63	3.83	16.93	3.11	0.73	371.13	388.27	0.043
0	2	0	0	0	1	11	17.88	4.23	15.57	3.11	0.67	411.28	418.22	0.043
0	2	0	2	0	1	11	18.43	4.29	15.35	3.14	0.66	413.62	427.50	0.043
0	2	0	2	0	1	12	14.62	3.82	17.07	3.10	0.73	408.53	422.41	0.043
0	2	0	0	0	1	5	18.79	4.34	15.26	3.14	0.65	413.22	420.15	0.043
0	1	1	1	2	1	4	20.01	4.47	14.96	3.21	0.63	389.88	403.64	0.042
2	2	0	1	2	2	10	16.86	4.11	16.37	3.04	0.69	421.63	441.91	0.042
0	2	0	2	1	1	7	14.81	3.85	17.34	3.13	0.72	429.95	443.70	0.042
0	2	0	2	0	2	12	14.11	3.76	17.68	3.16	0.74	410.24	427.58	0.042
0	2	0	1	0	0	5	19.41	4.41	15.36	3.19	0.64	413.06	420.00	0.042
2	2	0	1	0	2	9	14.23	3.77	17.70	3.15	0.74	361.85	382.66	0.042
0	2	0	0	0	2	12	15.22	3.90	17.27	3.14	0.72	408.49	418.89	0.042
2	1	0	1	2	1	4	20.38	4.51	15.06	3.24	0.62	391.61	408.80	0.041

0	2	1	0	2	1	8	20.94	4.58	14.84	3.31	0.61	455.98	466.18	0.041
0	2	0	2	0	0	7	19.17	4.38	15.66	3.20	0.64	413.41	423.82	0.041
2	2	0	2	1	2	9	14.90	3.86	17.67	3.16	0.72	364.42	388.43	0.041
2	2	0	2	0	2	9	14.42	3.80	17.91	3.19	0.73	361.13	385.40	0.041
0	2	0	1	0	0	3	20.07	4.48	15.37	3.23	0.63	410.62	417.55	0.041
2	2	0	2	2	2	10	17.95	4.24	16.54	3.08	0.67	423.47	447.13	0.040
0	2	0	0	2	2	4	15.89	3.99	17.56	3.17	0.70	461.51	471.81	0.040
0	2	0	1	0	1	5	20.41	4.52	15.50	3.27	0.62	413.21	423.62	0.040
0	2	0	2	1	2	2	15.86	3.98	17.61	3.18	0.71	426.11	443.41	0.040
0	2	0	0	1	1	7	15.81	3.98	17.67	3.18	0.71	428.11	434.99	0.040
0	2	0	0	0	1	3	20.51	4.53	15.49	3.27	0.62	410.96	417.90	0.040
0	2	0	1	2	2	2	15.58	3.95	17.86	3.20	0.71	445.65	459.46	0.040
0	2	0	0	2	2	2	15.68	3.96	17.86	3.20	0.71	444.09	454.44	0.040
2	1	1	0	2	1	5	15.96	4.00	17.75	3.18	0.70	465.83	482.97	0.040
0	1	0	0	1	0	4	15.00	3.87	18.20	3.23	0.72	474.41	477.86	0.040
0	2	0	1	0	1	7	19.28	4.39	16.23	3.24	0.64	411.23	421.63	0.040
2	2	0	2	2	2	11	21.18	4.60	15.37	3.34	0.61	438.38	461.97	0.039
0	2	0	2	0	1	7	19.34	4.40	16.41	3.26	0.64	413.01	426.88	0.039
0	2	0	1	0	2	7	19.43	4.41	16.38	3.26	0.64	413.07	426.94	0.039
0	2	1	0	2	1	5	18.96	4.35	16.67	3.12	0.65	497.05	507.32	0.039
1	2	1	2	2	1	4	22.20	4.71	15.15	3.38	0.59	387.92	408.52	0.039
0	2	0	0	0	2	7	20.16	4.49	16.19	3.30	0.63	412.55	422.96	0.039
1	0	0	1	2	0	4	19.71	4.44	16.50	3.36	0.63	539.68	550.01	0.038
2	2	0	1	2	2	3	18.29	4.28	17.29	3.19	0.66	369.36	390.02	0.038
2	2	0	1	0	2	8	14.67	3.83	19.15	3.33	0.73	355.10	375.91	0.038
0	2	1	0	2	1	7	23.07	4.80	15.12	3.45	0.57	480.75	490.97	0.038
1	2	1	0	2	1	7	23.08	4.80	15.12	3.45	0.57	479.83	493.46	0.038
2	2	0	2	1	1	3	22.42	4.73	15.53	3.40	0.58	333.62	354.35	0.038
0	2	0	2	1	1	8	17.60	4.19	17.99	3.24	0.67	430.24	443.97	0.037
0	2	0	0	1	2	7	16.76	4.09	18.44	3.28	0.69	428.28	438.60	0.037
0	2	0	1	2	2	10	19.04	4.36	17.32	3.20	0.65	464.41	477.93	0.037
1	1	0	1	1	0	4	22.28	4.72	15.74	3.41	0.59	370.50	380.87	0.037
2	2	1	2	2	1	4	23.04	4.80	15.37	3.45	0.57	389.87	413.91	0.037
2	0	0	0	2	0	3	19.49	4.42	17.19	3.43	0.64	635.17	645.52	0.037
0	2	0	2	0	0	12	15.35	3.92	19.26	3.37	0.71	409.43	419.83	0.037
0	2	0	2	0	1	2	16.31	4.04	18.87	3.33	0.70	415.46	429.33	0.037
0	2	0	1	1	1	7	17.06	4.13	18.51	3.29	0.68	428.50	438.81	0.037
0	2	0	2	2	2	10	19.29	4.39	17.43	3.22	0.64	466.41	483.31	0.037
0	2	0	2	2	1	11	22.70	4.76	15.72	3.10	0.58	495.13	508.61	0.037
1	2	0	2	0	0	9	15.53	3.94	19.35	3.37	0.71	368.46	382.33	0.037
2	2	0	2	0	1	8	15.01	3.87	19.80	3.41	0.72	354.37	375.18	0.036
2	0	0	0	2	0	2	16.67	4.08	19.04	3.34	0.69	495.33	505.70	0.036
0	1	0	1	2	1	4	23.11	4.81	15.75	3.47	0.57	398.96	409.28	0.036
2	1	0	0	1	0	4	16.40	4.05	19.20	3.37	0.70	463.26	473.62	0.036
2	1	0	1	2	0	10	23.49	4.85	15.58	3.62	0.56	519.23	532.77	0.036

0	2	0	2	1	2	3	23.29	4.83	15.68	3.48	0.57	422.67	439.95	0.036
1	1	0	1	2	0	10	23.55	4.85	15.60	3.63	0.56	517.24	527.39	0.036
0	2	0	1	1	0	12	24.46	4.95	15.14	3.56	0.55	508.31	515.14	0.036
2	2	0	2	1	1	11	17.52	4.19	18.83	3.34	0.67	381.46	401.98	0.036
1	2	0	2	1	1	11	17.77	4.22	18.76	3.33	0.67	386.17	403.27	0.036
0	2	0	1	1	2	7	23.21	4.82	15.94	3.50	0.57	429.44	443.20	0.036
2	2	0	2	1	1	9	16.81	4.10	19.38	3.38	0.69	364.98	385.55	0.035
1	2	0	0	0	1	3	16.53	4.07	19.59	3.41	0.69	362.54	372.94	0.035
0	2	0	0	2	2	5	17.65	4.20	19.45	3.41	0.67	451.02	461.30	0.035
1	2	0	1	0	2	8	15.72	3.96	20.57	3.51	0.71	365.13	382.47	0.034
1	2	0	1	0	0	3	17.15	4.14	19.90	3.46	0.68	362.24	372.65	0.034
1	2	0	2	1	2	3	18.36	4.29	19.24	3.40	0.66	376.08	396.81	0.034
1	2	1	0	2	1	5	20.97	4.58	17.84	3.31	0.61	490.50	504.20	0.034
2	1	1	2	2	1	3	24.37	4.94	16.12	3.57	0.55	381.35	405.48	0.034
1	2	0	0	0	2	9	16.88	4.11	20.25	3.49	0.69	368.61	382.48	0.034
1	2	0	2	0	1	8	16.13	4.02	20.89	3.55	0.70	364.84	382.18	0.034
2	1	0	2	2	1	3	24.78	4.98	16.23	3.61	0.54	379.86	400.54	0.033
0	2	0	2	0	1	8	23.37	4.83	17.03	3.57	0.57	407.16	421.04	0.033
0	2	0	0	1	2	8	19.93	4.46	19.00	3.42	0.63	428.54	438.84	0.033
0	2	0	0	2	2	3	21.95	4.68	17.96	3.35	0.59	448.93	459.26	0.033
0	2	0	2	1	0	11	24.44	4.94	16.61	3.26	0.55	455.20	465.46	0.033
0	2	0	1	0	2	2	18.57	4.31	20.02	3.51	0.66	415.26	429.13	0.033
1	2	0	1	0	2	3	18.10	4.25	20.41	3.54	0.66	366.09	383.43	0.033
1	2	0	2	0	1	3	18.14	4.26	20.43	3.54	0.66	366.09	383.43	0.032
1	2	0	1	0	1	3	18.17	4.26	20.45	3.54	0.66	364.09	377.96	0.032
0	2	0	0	1	0	11	26.86	5.18	15.51	3.69	0.50	576.97	580.39	0.032
1	2	0	2	2	2	2	21.03	4.59	18.89	3.43	0.61	365.75	386.46	0.032
0	2	0	1	0	2	11	24.52	4.95	16.88	3.64	0.54	412.81	426.68	0.032
2	2	0	1	0	1	12	17.69	4.21	20.90	3.58	0.67	361.33	378.67	0.032
2	1	0	1	1	0	4	25.29	5.03	16.55	3.67	0.53	372.04	385.86	0.032
1	2	0	2	0	0	3	18.46	4.30	20.60	3.57	0.66	364.10	377.98	0.032
1	2	0	1	0	1	7	17.78	4.22	21.12	3.61	0.67	367.87	381.74	0.032
2	2	0	2	0	2	4	18.66	4.32	20.60	3.57	0.65	361.07	385.35	0.032
0	2	0	1	1	2	8	20.72	4.55	19.40	3.49	0.62	430.53	444.27	0.032
1	2	0	2	0	1	6	17.86	4.23	21.14	3.61	0.67	369.52	386.86	0.032
2	2	0	2	0	0	3	25.72	5.07	16.64	3.70	0.52	320.84	338.18	0.031
0	1	0	0	2	1	4	20.06	4.48	20.14	3.55	0.63	488.53	495.40	0.031
2	2	0	1	0	0	4	18.84	4.34	20.90	3.61	0.65	358.79	372.66	0.031
1	2	0	1	0	1	12	18.26	4.27	21.26	3.64	0.66	367.61	381.48	0.031
1	1	0	0	1	0	4	19.28	4.39	20.81	3.61	0.64	461.77	468.68	0.031
1	2	0	0	1	2	11	20.47	4.52	20.09	3.55	0.62	384.18	397.86	0.031
1	2	0	1	0	1	5	19.06	4.37	20.97	3.62	0.65	367.23	381.10	0.031
0	2	0	1	1	1	11	25.90	5.09	16.85	3.73	0.52	425.53	435.80	0.031
1	2	0	0	0	2	3	19.14	4.38	20.95	3.62	0.64	364.18	378.06	0.031
1	2	0	1	0	2	6	18.41	4.29	21.39	3.65	0.66	369.64	386.98	0.031

1	2	0	1	0	0	4	19.16	4.38	21.10	3.64	0.64	365.58	375.98	0.031
1	2	0	1	0	2	7	18.34	4.28	21.60	3.67	0.66	369.47	386.81	0.031
2	1	0	0	1	0	6	26.57	5.16	16.62	3.75	0.51	435.82	446.16	0.030
2	2	0	0	0	1	4	19.27	4.39	21.15	3.65	0.64	359.14	373.02	0.030
1	2	0	0	0	1	4	19.26	4.39	21.17	3.65	0.64	365.76	376.17	0.030
1	1	1	2	2	1	3	26.59	5.16	16.74	3.77	0.51	380.33	401.01	0.030
2	2	0	1	0	1	5	19.55	4.42	21.21	3.66	0.64	359.96	377.30	0.030
1	2	0	2	0	1	7	18.70	4.32	21.85	3.71	0.65	369.36	386.70	0.030
2	2	0	2	0	0	9	19.44	4.41	21.56	3.69	0.64	362.65	379.99	0.030
2	1	1	0	2	1	6	27.22	5.22	16.76	3.80	0.49	456.37	473.48	0.029
2	2	0	1	0	1	7	19.22	4.38	21.85	3.72	0.64	361.81	379.15	0.029
2	1	0	0	2	1	6	27.33	5.23	16.79	3.81	0.49	454.45	468.13	0.029
2	2	0	1	0	2	7	19.22	4.38	21.96	3.73	0.64	363.52	384.33	0.029
2	2	0	2	0	1	7	19.27	4.39	22.01	3.74	0.64	363.46	384.27	0.029
2	2	0	2	0	1	6	19.40	4.40	21.97	3.74	0.64	363.00	383.81	0.029
0	2	1	2	2	1	4	27.84	5.28	16.59	3.83	0.48	396.25	413.42	0.029
0	2	0	2	1	1	4	22.18	4.71	20.21	3.65	0.59	424.51	438.31	0.029
2	2	0	0	0	2	7	19.72	4.44	21.79	3.72	0.63	362.26	379.60	0.029
1	1	0	0	1	0	6	27.47	5.24	16.86	3.82	0.49	433.88	440.78	0.029
0	2	0	0	1	1	10	21.86	4.68	20.44	3.66	0.59	416.48	423.33	0.029
1	1	1	0	2	1	6	27.68	5.26	16.88	3.84	0.49	454.48	468.16	0.029
0	2	0	1	0	1	12	26.77	5.17	17.51	3.83	0.50	411.50	421.91	0.029
2	2	1	2	2	2	5	28.41	5.33	16.51	3.85	0.47	406.91	434.31	0.029
1	2	0	0	1	2	3	21.56	4.64	21.01	3.71	0.60	372.55	386.37	0.029
2	2	0	1	0	2	6	19.93	4.46	22.16	3.78	0.63	363.15	383.96	0.028
0	2	0	2	0	2	2	24.83	4.98	19.01	3.74	0.54	402.44	419.79	0.028
0	1	0	1	1	0	4	27.74	5.27	17.20	3.87	0.48	379.54	386.45	0.028
0	2	0	1	1	2	10	22.23	4.72	20.87	3.73	0.59	416.16	429.86	0.028
2	1	0	2	1	0	3	27.84	5.28	17.19	3.87	0.48	361.96	379.26	0.028
0	2	0	1	0	0	9	27.23	5.22	17.61	3.87	0.49	410.28	417.21	0.028
2	2	1	1	2	1	5	28.79	5.37	16.61	3.88	0.47	402.91	423.46	0.028
1	0	0	0	2	0	5	25.79	5.08	18.70	3.89	0.52	697.98	704.85	0.028
1	1	0	0	2	1	6	28.30	5.32	17.04	3.88	0.47	452.52	462.78	0.028
1	2	0	0	0	2	7	20.61	4.54	22.19	3.79	0.62	368.77	382.64	0.028
0	2	0	0	1	1	6	22.59	4.75	21.15	3.77	0.58	425.47	432.36	0.027
1	1	0	2	2	1	3	28.39	5.33	17.22	3.91	0.47	378.66	395.89	0.027
0	2	1	1	2	1	3	25.16	5.02	19.47	3.66	0.53	422.53	436.30	0.027
2	2	0	1	0	0	5	21.23	4.61	22.18	3.82	0.61	359.90	373.77	0.027
1	0	0	1	2	0	3	21.94	4.68	21.76	3.83	0.59	553.47	563.82	0.027
2	2	0	2	0	0	7	21.11	4.59	22.34	3.82	0.61	362.43	379.77	0.027
2	1	0	0	1	0	2	21.42	4.63	22.15	3.83	0.60	386.54	396.94	0.027
2	2	0	0	0	2	9	21.17	4.60	22.35	3.83	0.61	362.74	380.08	0.027
2	2	0	1	0	1	4	21.47	4.63	22.20	3.83	0.60	359.82	377.16	0.027
0	2	0	1	1	1	8	23.63	4.86	20.81	3.78	0.56	428.73	439.03	0.027
1	2	0	1	0	1	4	21.59	4.65	22.31	3.85	0.60	366.97	380.85	0.027

0	2	0	0	1	2	5	23.50	4.85	21.08	3.79	0.56	413.29	423.63	0.027
0	2	0	1	1	1	5	23.59	4.86	21.03	3.79	0.56	412.68	423.02	0.027
1	2	0	1	0	0	2	21.75	4.66	22.31	3.86	0.60	347.85	358.25	0.027
1	2	0	1	1	1	3	22.95	4.79	21.70	3.85	0.57	372.28	386.10	0.026
0	2	0	1	1	2	5	23.87	4.89	21.25	3.83	0.56	413.17	426.95	0.026
2	1	1	0	2	1	4	23.20	4.82	21.75	3.86	0.57	460.09	477.28	0.026
1	2	0	1	0	1	9	21.93	4.68	22.67	3.90	0.59	369.04	382.92	0.026
2	2	1	0	2	1	9	30.20	5.50	16.83	3.94	0.44	477.37	494.32	0.026
0	1	0	0	2	0	11	29.06	5.39	17.71	3.78	0.46	669.38	672.76	0.026
2	2	0	0	0	1	5	22.20	4.71	22.71	3.92	0.59	360.12	374.00	0.026
1	2	0	2	0	0	7	22.07	4.70	22.83	3.92	0.59	368.90	382.78	0.026
1	2	1	1	2	1	5	30.24	5.50	16.96	3.98	0.44	400.98	418.11	0.026
2	2	0	0	1	2	11	23.62	4.86	21.90	3.88	0.56	379.71	396.81	0.026
1	1	2	1	2	2	3	23.49	4.85	22.01	3.91	0.56	397.63	421.76	0.026
0	1	1	0	2	1	4	23.76	4.87	22.05	3.92	0.56	476.02	486.33	0.025
2	1	0	0	2	0	11	28.61	5.35	18.51	3.97	0.47	669.97	680.10	0.025
2	2	0	2	0	2	12	21.96	4.69	23.56	3.99	0.59	363.39	387.66	0.025
1	2	0	2	0	1	11	22.83	4.78	22.93	3.96	0.58	369.59	386.93	0.025
2	2	1	1	2	1	6	30.69	5.54	17.15	4.02	0.43	420.09	440.59	0.025
2	1	0	0	2	1	4	23.98	4.90	22.16	3.94	0.55	477.65	491.40	0.025
1	1	0	0	2	0	11	28.70	5.36	18.72	4.02	0.47	668.34	675.09	0.025
0	1	1	2	2	1	3	30.24	5.50	17.67	4.05	0.44	379.37	396.60	0.025
1	2	0	0	0	1	9	23.04	4.80	23.23	4.01	0.57	367.09	377.49	0.025
0	2	0	2	2	1	10	31.62	5.62	16.78	3.50	0.41	486.37	499.89	0.025
0	2	0	2	1	2	7	30.20	5.50	17.89	4.07	0.44	428.03	445.22	0.025
1	2	0	1	1	1	11	24.75	4.98	22.28	3.98	0.54	384.35	398.03	0.024
1	0	0	0	2	0	8	30.11	5.49	18.22	4.03	0.44	628.39	635.21	0.024
0	2	0	2	2	2	5	25.16	5.02	22.03	3.98	0.53	449.65	466.78	0.024
1	2	0	0	0	1	12	23.36	4.83	23.50	4.05	0.57	366.96	377.37	0.024
1	2	0	1	1	2	3	24.62	4.96	22.54	4.02	0.54	374.17	391.45	0.024
1	2	0	0	0	1	11	23.32	4.83	23.61	4.05	0.57	366.16	376.57	0.024
2	2	0	1	0	2	12	22.82	4.78	24.02	4.07	0.58	361.41	382.22	0.024
0	1	1	0	2	1	6	30.95	5.56	17.72	4.09	0.43	453.46	463.72	0.024
1	2	0	1	0	0	5	23.57	4.86	23.44	4.06	0.56	367.03	377.43	0.024
1	2	0	1	0	0	9	23.60	4.86	23.51	4.06	0.56	367.10	377.51	0.024
1	2	0	2	1	1	3	24.82	4.98	22.64	4.04	0.54	374.19	391.46	0.024
1	2	0	2	0	2	12	23.15	4.81	24.12	4.09	0.57	370.52	391.33	0.024
1	2	0	2	0	2	6	23.62	4.86	23.80	4.09	0.56	371.09	391.90	0.024
1	2	0	1	0	0	11	23.67	4.87	23.78	4.09	0.56	366.10	376.51	0.024
2	2	0	2	0	1	12	23.20	4.82	24.22	4.11	0.57	361.48	382.29	0.023
2	2	0	2	0	0	11	23.76	4.87	23.82	4.10	0.56	361.94	379.28	0.023
1	2	1	1	2	1	6	31.85	5.64	17.44	4.11	0.41	418.15	435.23	0.023
2	2	0	0	0	1	11	23.80	4.88	23.84	4.10	0.56	359.94	373.81	0.023
2	2	0	1	0	1	11	23.82	4.88	23.85	4.10	0.56	361.94	379.28	0.023
2	2	0	2	0	1	11	23.83	4.88	23.86	4.10	0.56	363.94	384.74	0.023

2	2	0	0	0	2	11	23.83	4.88	23.86	4.10	0.56	361.94	379.28	0.023
0	2	0	0	1	2	9	30.41	5.51	18.64	4.14	0.44	417.30	427.58	0.023
2	2	0	1	0	2	11	23.88	4.89	23.88	4.11	0.56	363.94	384.74	0.023
1	2	0	1	0	0	12	24.00	4.90	23.78	4.11	0.55	367.02	377.42	0.023
1	2	0	2	0	2	4	24.40	4.94	23.52	4.13	0.55	367.80	388.61	0.023
1	2	0	1	1	1	4	25.26	5.03	22.85	4.07	0.53	379.47	393.28	0.023
1	2	0	0	0	1	5	24.20	4.92	23.77	4.12	0.55	367.07	377.48	0.023
1	1	0	2	1	0	3	31.40	5.60	18.05	4.14	0.42	360.77	374.61	0.023
2	2	0	1	0	1	9	24.31	4.93	23.88	4.14	0.55	362.87	380.21	0.023
2	2	0	2	0	2	6	24.18	4.92	24.06	4.15	0.55	364.80	389.07	0.023
2	2	0	1	0	0	11	24.27	4.93	24.05	4.14	0.55	359.94	373.81	0.023
0	2	0	1	0	2	8	30.74	5.54	18.83	4.16	0.43	408.24	422.11	0.023
2	2	0	1	1	1	4	25.66	5.07	23.16	4.13	0.52	373.39	390.65	0.023
1	2	0	0	1	2	4	25.76	5.08	23.09	4.12	0.52	379.65	393.46	0.023
2	2	0	0	0	1	9	24.72	4.97	24.07	4.18	0.54	360.88	374.75	0.022
1	0	0	0	2	0	4	28.53	5.34	21.01	3.99	0.47	699.15	706.03	0.022
2	1	0	1	2	0	11	32.51	5.70	17.72	4.19	0.40	547.92	561.42	0.022
0	1	0	1	2	0	10	32.08	5.66	18.13	4.24	0.40	525.12	531.88	0.022
2	2	0	1	0	0	9	25.07	5.01	24.24	4.21	0.53	360.89	374.76	0.022
0	2	0	2	1	2	10	26.65	5.16	23.05	4.17	0.51	417.81	434.94	0.022
2	2	0	0	0	2	12	24.51	4.95	24.89	4.22	0.54	359.56	376.90	0.022
1	2	0	2	2	2	11	31.68	5.63	18.88	4.21	0.41	442.11	462.33	0.022
2	2	0	2	1	2	7	26.39	5.14	23.44	4.17	0.51	379.85	403.92	0.022
0	0	0	1	2	0	2	25.81	5.08	24.10	4.20	0.52	603.89	610.81	0.022
1	2	0	2	0	1	12	24.80	4.98	25.01	4.26	0.54	368.65	385.99	0.022
1	2	0	1	0	2	12	24.96	5.00	25.10	4.27	0.54	368.57	385.91	0.021
1	1	1	0	2	1	4	26.82	5.18	23.52	4.21	0.50	477.90	491.65	0.021
2	2	0	0	1	2	4	26.77	5.17	23.68	4.23	0.50	373.72	390.98	0.021
2	2	0	2	0	2	10	26.53	5.15	23.90	4.26	0.51	360.95	385.23	0.021
1	2	0	0	1	2	9	26.47	5.14	24.09	4.25	0.51	372.52	386.24	0.021
1	0	0	2	2	0	2	26.22	5.12	24.43	4.30	0.51	475.74	489.58	0.021
2	2	0	2	0	2	11	26.04	5.10	24.61	4.30	0.52	364.24	388.51	0.021
1	2	0	2	0	1	4	26.13	5.11	24.59	4.30	0.51	368.71	386.05	0.021
2	2	0	0	0	1	12	26.06	5.11	24.75	4.31	0.52	360.94	374.81	0.021
2	2	1	0	2	1	5	29.39	5.42	21.83	4.09	0.45	490.97	508.10	0.021
1	2	0	0	0	1	7	26.14	5.11	24.76	4.32	0.51	367.17	377.58	0.021
1	1	0	0	2	1	8	33.21	5.76	18.51	4.28	0.38	438.29	448.50	0.021
2	2	0	0	0	1	7	26.22	5.12	24.79	4.32	0.51	360.85	374.72	0.021
2	2	0	2	0	2	5	26.51	5.15	24.64	4.33	0.51	362.37	386.65	0.021
1	2	0	1	0	0	7	26.30	5.13	24.83	4.33	0.51	367.18	377.58	0.021
0	2	0	2	1	2	5	28.00	5.29	23.38	4.25	0.48	414.46	431.69	0.021
1	2	0	0	0	2	11	26.29	5.13	24.96	4.34	0.51	367.98	381.86	0.021
2	2	0	1	1	1	11	27.62	5.26	23.81	4.27	0.49	379.90	397.01	0.020
0	2	0	1	2	2	5	29.21	5.40	22.40	4.15	0.46	449.77	463.47	0.020
0	1	0	0	1	0	6	33.67	5.80	18.37	4.28	0.37	443.11	446.55	0.020

1	2	0	1	0	2	4	26.68	5.16	24.85	4.35	0.50	368.64	385.98	0.020
2	2	0	1	0	0	7	26.58	5.16	24.95	4.36	0.51	360.87	374.74	0.020
1	2	0	1	0	2	5	26.84	5.18	24.75	4.36	0.50	367.15	384.49	0.020
2	0	0	1	2	0	3	33.63	5.80	18.54	4.30	0.38	503.54	517.34	0.020
2	2	0	1	0	0	12	26.64	5.16	25.00	4.36	0.51	360.96	374.83	0.020
1	2	0	2	0	0	4	26.79	5.18	24.87	4.36	0.50	366.75	380.62	0.020
0	2	0	2	0	2	8	25.69	5.07	25.91	4.43	0.52	404.80	422.14	0.020
1	0	0	1	2	0	5	34.20	5.85	18.22	4.26	0.36	534.41	544.72	0.020
0	1	0	2	2	1	3	33.88	5.82	18.53	4.31	0.37	381.76	395.55	0.020
1	2	0	0	0	2	12	26.16	5.11	25.69	4.38	0.51	366.62	380.49	0.020
1	2	1	1	2	1	3	30.51	5.52	21.91	4.14	0.43	413.97	431.18	0.020
1	2	0	1	0	2	11	27.16	5.21	25.14	4.40	0.50	367.89	385.23	0.020
1	2	0	0	0	0	2	27.61	5.25	25.39	4.45	0.49	365.26	372.20	0.019
1	2	0	0	0	0	3	27.61	5.25	25.39	4.45	0.49	365.26	372.20	0.019
1	2	0	0	0	0	4	27.61	5.25	25.39	4.45	0.49	365.26	372.20	0.019
1	2	0	0	0	0	5	27.61	5.25	25.39	4.45	0.49	365.26	372.20	0.019
1	2	0	0	0	0	6	27.61	5.25	25.39	4.45	0.49	365.26	372.20	0.019
1	2	0	0	0	0	7	27.61	5.25	25.39	4.45	0.49	365.26	372.20	0.019
1	2	0	0	0	0	8	27.61	5.25	25.39	4.45	0.49	365.26	372.20	0.019
1	2	0	0	0	0	9	27.61	5.25	25.39	4.45	0.49	365.26	372.20	0.019
1	2	0	0	0	0	10	27.61	5.25	25.39	4.45	0.49	365.26	372.20	0.019
1	2	0	0	0	0	11	27.61	5.25	25.39	4.45	0.49	365.26	372.20	0.019
1	2	0	0	0	0	12	27.61	5.25	25.39	4.45	0.49	365.26	372.20	0.019
1	2	0	0	0	2	4	27.73	5.27	25.28	4.45	0.48	366.84	380.71	0.019
0	2	0	1	2	2	4	31.54	5.62	21.63	4.09	0.41	463.25	476.98	0.019
1	2	0	2	0	2	11	27.87	5.28	25.27	4.45	0.48	369.92	390.72	0.019
1	2	0	1	0	1	11	27.84	5.28	25.35	4.46	0.48	365.93	379.81	0.019
0	2	0	2	1	0	12	34.09	5.84	19.26	4.40	0.37	486.41	496.66	0.019
1	2	0	2	0	0	11	27.68	5.26	25.59	4.46	0.49	367.94	381.82	0.019
1	2	0	1	1	2	4	28.96	5.38	24.47	4.40	0.46	380.81	398.07	0.019
2	2	0	1	0	2	5	28.19	5.31	25.33	4.47	0.48	360.38	381.19	0.019
0	2	1	1	2	1	5	35.65	5.97	18.28	4.36	0.34	409.88	423.58	0.018
0	2	0	2	0	2	3	34.39	5.86	19.55	4.42	0.36	413.14	430.48	0.018
0	1	0	1	1	0	2	28.40	5.33	25.69	4.51	0.47	398.45	405.38	0.018
0	2	0	2	1	1	5	29.94	5.47	24.16	4.41	0.44	412.62	426.41	0.018
1	2	0	2	0	0	6	28.41	5.33	25.83	4.52	0.47	368.48	382.35	0.018
1	2	0	2	0	1	5	28.79	5.37	25.52	4.52	0.47	367.25	384.59	0.018
2	2	1	1	2	1	3	31.90	5.65	22.45	4.25	0.41	415.93	436.59	0.018
2	2	0	1	1	2	4	29.66	5.45	24.89	4.47	0.45	374.38	395.08	0.018
1	2	0	0	0	2	6	28.71	5.36	25.96	4.55	0.47	368.49	382.37	0.018
2	2	0	2	0	0	12	28.13	5.30	26.58	4.56	0.48	359.92	377.26	0.018
1	1	1	0	2	1	8	35.46	5.95	19.09	4.44	0.34	440.03	453.64	0.018
2	2	0	0	0	0	2	28.93	5.38	25.94	4.56	0.46	359.04	369.44	0.018
2	2	0	0	0	0	3	28.93	5.38	25.94	4.56	0.46	359.04	369.44	0.018
2	2	0	0	0	0	4	28.93	5.38	25.94	4.56	0.46	359.04	369.44	0.018

2	2	0	0	0	0	5	28.93	5.38	25.94	4.56	0.46	359.04	369.44	0.018
2	2	0	0	0	0	6	28.93	5.38	25.94	4.56	0.46	359.04	369.44	0.018
2	2	0	0	0	0	7	28.93	5.38	25.94	4.56	0.46	359.04	369.44	0.018
2	2	0	0	0	0	8	28.93	5.38	25.94	4.56	0.46	359.04	369.44	0.018
2	2	0	0	0	0	9	28.93	5.38	25.94	4.56	0.46	359.04	369.44	0.018
2	2	0	0	0	0	10	28.93	5.38	25.94	4.56	0.46	359.04	369.44	0.018
2	2	0	0	0	0	11	28.93	5.38	25.94	4.56	0.46	359.04	369.44	0.018
2	2	0	0	0	0	12	28.93	5.38	25.94	4.56	0.46	359.04	369.44	0.018
0	2	0	0	1	1	5	30.24	5.50	24.58	4.46	0.44	414.23	421.12	0.018
1	2	0	2	0	2	10	29.72	5.45	25.13	4.51	0.45	366.94	387.74	0.018
0	2	1	2	2	2	5	36.23	6.02	18.44	4.41	0.33	413.77	434.32	0.018
0	1	0	0	2	1	6	35.83	5.99	18.87	4.42	0.33	461.43	468.27	0.018
1	1	0	0	2	1	4	30.08	5.48	24.92	4.49	0.44	476.14	486.45	0.018
1	2	0	2	0	0	12	28.59	5.35	26.78	4.60	0.47	366.84	380.71	0.018
2	2	0	2	0	1	5	29.65	5.44	25.84	4.59	0.45	360.43	381.24	0.017
1	2	0	2	1	2	11	31.00	5.57	24.83	4.51	0.42	386.97	407.49	0.017
2	2	0	0	1	2	9	30.20	5.50	25.96	4.60	0.44	365.19	382.33	0.017
0	1	0	2	1	0	3	36.45	6.04	19.24	4.50	0.32	363.84	374.22	0.017
0	1	1	0	2	1	8	36.54	6.04	19.36	4.52	0.32	438.10	448.31	0.017
2	2	0	1	1	2	10	31.48	5.61	25.03	4.56	0.42	369.73	390.28	0.017
0	2	0	0	2	2	12	30.80	5.55	25.91	4.61	0.43	496.53	506.61	0.017
1	2	0	1	1	1	9	30.74	5.54	25.97	4.62	0.43	372.88	386.60	0.017
2	1	2	2	2	2	4	36.87	6.07	19.21	4.51	0.32	365.76	396.70	0.016
0	2	1	2	2	1	2	33.26	5.77	23.33	4.40	0.38	391.09	408.35	0.016
0	1	0	2	2	0	8	38.44	6.20	17.94	3.87	0.29	495.27	505.48	0.016
1	1	0	1	1	0	2	31.07	5.57	26.83	4.74	0.42	389.85	400.25	0.016
2	1	0	0	2	1	8	37.38	6.11	19.57	4.58	0.31	439.89	453.50	0.016
2	2	0	2	0	0	4	31.63	5.62	26.80	4.76	0.41	358.95	376.29	0.015
2	2	0	2	0	1	4	31.76	5.64	26.85	4.77	0.41	360.95	381.76	0.015
0	2	0	0	1	2	6	32.97	5.74	25.60	4.67	0.39	425.85	436.18	0.015
2	2	0	1	0	2	4	31.95	5.65	26.95	4.79	0.41	360.71	381.52	0.015
0	2	0	2	1	1	6	33.27	5.77	25.70	4.69	0.38	427.83	441.60	0.015
1	2	0	2	1	2	7	33.01	5.75	26.13	4.72	0.39	386.31	406.94	0.015
1	1	0	2	2	1	4	38.23	6.18	19.75	4.63	0.29	374.47	391.66	0.015
0	2	1	1	2	1	6	38.90	6.24	19.09	4.58	0.28	426.90	440.56	0.015
0	2	0	1	1	2	6	33.63	5.80	25.93	4.73	0.38	425.75	439.52	0.014
0	2	0	1	1	1	6	33.90	5.82	25.90	4.73	0.37	425.83	436.16	0.014
0	2	0	2	1	2	8	34.65	5.89	25.30	4.70	0.36	432.13	449.30	0.014
0	2	0	2	1	0	10	39.21	6.26	19.47	4.02	0.27	452.66	462.94	0.014
1	2	0	1	0	0	6	33.14	5.76	27.56	4.89	0.38	366.76	377.17	0.014
1	1	0	0	1	0	8	38.79	6.23	20.03	4.69	0.28	415.99	422.86	0.014
1	2	0	0	0	1	6	33.20	5.76	27.59	4.89	0.38	366.73	377.13	0.014
2	2	0	2	0	0	8	33.04	5.75	27.81	4.90	0.39	359.57	376.92	0.014
2	2	0	2	0	0	5	33.55	5.79	27.23	4.88	0.38	358.56	375.90	0.014
2	2	0	1	1	1	9	33.67	5.80	27.33	4.87	0.37	365.47	382.61	0.014

2	2	0	2	0	0	6	33.43	5.78	27.73	4.92	0.38	362.11	379.45	0.014
0	2	0	2	1	2	6	34.67	5.89	26.21	4.80	0.36	427.45	444.67	0.014
1	1	1	2	2	1	4	39.27	6.27	19.99	4.70	0.27	376.43	397.05	0.014
1	0	0	1	2	0	6	39.99	6.32	19.10	4.57	0.26	546.92	557.20	0.013
1	2	0	2	0	0	8	33.60	5.80	27.93	4.94	0.38	367.86	381.73	0.013
2	2	0	0	0	2	6	33.71	5.81	27.83	4.94	0.37	362.12	379.46	0.013
0	2	0	0	0	1	9	38.95	6.24	20.63	4.74	0.28	409.53	416.47	0.013
1	2	1	0	2	1	9	40.00	6.32	19.29	4.64	0.26	477.45	491.01	0.013
2	2	0	2	1	2	10	35.04	5.92	26.38	4.83	0.35	371.63	395.61	0.013
2	1	0	0	2	1	2	34.97	5.91	27.01	4.89	0.35	398.25	412.07	0.013
2	2	0	0	0	2	4	34.48	5.87	27.84	4.97	0.36	358.82	376.16	0.013
1	2	0	1	0	1	6	34.54	5.88	28.09	5.00	0.36	367.51	381.38	0.013
2	1	0	2	2	1	4	40.03	6.33	20.17	4.75	0.26	376.39	397.02	0.013
1	2	0	0	0	2	8	34.62	5.88	28.22	5.01	0.36	368.00	381.87	0.013
1	2	1	2	2	1	2	37.07	6.09	24.88	4.70	0.31	383.12	403.82	0.013
2	2	0	0	0	2	8	35.14	5.93	28.45	5.05	0.35	360.03	377.37	0.012
1	0	0	2	2	0	5	41.24	6.42	19.58	4.68	0.23	487.55	501.28	0.012
0	2	0	2	1	1	10	36.62	6.05	26.96	4.94	0.32	417.13	430.83	0.012
0	2	0	0	1	2	10	36.69	6.06	26.94	4.94	0.32	415.13	425.41	0.012
2	2	0	1	0	1	6	35.76	5.98	28.49	5.08	0.34	361.21	378.55	0.012
0	2	0	2	0	1	6	40.47	6.36	21.20	4.85	0.25	412.15	426.02	0.012
0	1	0	0	2	1	8	40.97	6.40	20.43	4.82	0.24	445.26	452.06	0.012
2	2	0	0	0	2	5	36.10	6.01	28.22	5.07	0.33	358.91	376.25	0.012
2	2	0	1	1	2	7	36.88	6.07	27.46	4.99	0.31	378.75	399.38	0.011
2	2	0	0	0	1	6	36.63	6.05	28.78	5.14	0.32	360.19	374.06	0.011
0	2	0	2	2	1	12	41.40	6.43	20.90	4.88	0.23	523.62	537.07	0.011
1	2	0	2	0	0	5	37.01	6.08	28.45	5.12	0.31	365.78	379.65	0.011
1	2	0	1	1	2	11	37.77	6.15	27.17	5.00	0.30	385.46	402.56	0.011
2	2	0	1	0	0	6	36.89	6.07	28.86	5.15	0.31	360.22	374.09	0.011
0	1	1	2	2	1	4	41.78	6.46	20.56	4.86	0.22	374.75	391.94	0.011
0	2	0	1	1	1	10	37.97	6.16	27.17	5.01	0.29	415.20	425.47	0.011
1	2	0	1	1	1	2	37.71	6.14	27.91	5.07	0.30	358.37	372.21	0.011
0	2	1	0	2	1	9	42.37	6.51	19.88	4.79	0.21	476.62	486.79	0.011
0	1	0	0	1	0	3	37.59	6.13	29.24	5.21	0.30	479.29	482.75	0.010
0	2	0	0	2	2	6	38.55	6.21	27.66	5.05	0.28	470.24	480.49	0.010
2	0	0	2	2	0	3	42.57	6.52	20.48	4.87	0.21	463.68	480.94	0.010
1	2	0	1	1	2	9	38.32	6.19	28.47	5.16	0.29	375.22	392.37	0.010
2	2	0	0	1	1	10	38.92	6.24	27.57	5.07	0.28	369.02	382.72	0.010
2	1	0	0	1	0	8	42.78	6.54	20.95	4.95	0.21	417.57	427.88	0.010
2	2	0	2	1	2	11	39.19	6.26	28.44	5.18	0.27	383.10	407.05	0.010
1	2	0	0	1	1	4	39.34	6.27	28.20	5.15	0.27	378.93	389.28	0.010
1	2	0	2	2	2	9	40.15	6.34	26.88	4.96	0.25	424.66	445.00	0.009
1	2	0	0	0	2	5	38.97	6.24	29.23	5.27	0.28	366.12	379.99	0.009
1	2	0	0	1	1	11	39.67	6.30	28.13	5.16	0.26	384.75	395.01	0.009
1	2	0	1	0	1	8	39.17	6.26	29.66	5.31	0.27	368.07	381.95	0.009

0	1	1	0	2	1	2	40.30	6.35	28.53	5.22	0.25	416.88	427.25	0.009
1	2	0	2	1	1	4	40.38	6.35	28.41	5.21	0.25	380.43	397.68	0.009
2	1	0	0	1	0	3	39.95	6.32	30.05	5.37	0.26	476.17	486.55	0.009
0	2	0	0	1	1	12	40.72	6.38	28.43	5.20	0.24	431.94	438.77	0.009
0	2	0	2	2	2	9	43.58	6.60	22.32	5.10	0.19	463.53	480.48	0.009
2	2	0	1	1	2	11	40.72	6.38	28.78	5.26	0.24	381.18	401.70	0.008
1	2	0	1	1	2	7	41.16	6.42	28.83	5.27	0.24	384.85	402.04	0.008
1	1	1	1	2	1	2	41.06	6.41	29.06	5.30	0.24	370.88	388.16	0.008
1	2	0	0	0	2	10	41.16	6.42	29.47	5.37	0.24	365.85	379.72	0.008
1	2	0	1	1	2	10	41.78	6.46	28.15	5.22	0.22	375.05	392.18	0.008
1	2	0	0	0	1	8	40.92	6.40	30.19	5.42	0.24	366.10	376.51	0.008
0	2	0	0	1	2	11	44.84	6.70	21.71	5.09	0.17	424.81	435.07	0.008
1	2	0	1	0	0	8	41.37	6.43	30.31	5.45	0.23	366.17	376.57	0.008
1	2	0	0	1	1	3	42.01	6.48	29.21	5.34	0.22	375.55	385.91	0.008
2	2	0	0	1	1	11	42.17	6.49	29.20	5.35	0.22	379.64	393.32	0.007
0	2	0	1	1	1	12	42.33	6.51	28.87	5.30	0.21	433.91	444.16	0.007
1	1	0	2	1	0	4	45.30	6.73	21.48	5.09	0.16	352.62	366.44	0.007
0	1	0	0	1	0	8	45.36	6.74	21.49	5.10	0.16	423.25	426.69	0.007
2	2	0	0	1	1	4	42.39	6.51	29.28	5.36	0.21	373.30	387.10	0.007
1	2	0	2	1	2	10	42.89	6.55	28.51	5.29	0.20	377.05	397.60	0.007
1	2	0	2	0	0	10	42.66	6.53	29.78	5.44	0.21	365.66	379.53	0.007
1	2	0	0	2	0	7	45.03	6.71	23.48	5.09	0.16	747.22	754.04	0.007
0	2	0	1	0	1	9	45.54	6.75	22.17	5.17	0.15	411.33	421.74	0.007
0	2	0	0	1	2	12	43.04	6.56	29.06	5.34	0.20	433.89	444.14	0.007
1	2	0	1	0	2	10	42.87	6.55	29.69	5.44	0.20	367.54	384.88	0.007
1	2	0	0	0	1	10	42.61	6.53	30.41	5.50	0.21	364.20	374.61	0.007
1	2	0	2	0	1	10	43.04	6.56	29.75	5.45	0.20	367.54	384.88	0.007
1	2	0	1	0	1	10	43.26	6.58	29.84	5.47	0.20	365.55	379.42	0.007
1	1	0	0	1	0	3	42.96	6.55	31.05	5.57	0.20	474.25	481.17	0.007
1	2	0	1	0	0	10	43.69	6.61	30.57	5.56	0.19	363.99	374.39	0.006
2	2	0	1	1	2	9	43.96	6.63	30.36	5.53	0.18	368.00	388.57	0.006
1	2	0	0	1	1	9	43.98	6.63	30.47	5.54	0.18	371.99	382.28	0.006
2	1	1	1	2	1	5	46.91	6.85	21.47	5.15	0.13	389.38	409.95	0.006
2	1	0	2	1	0	4	46.91	6.85	21.81	5.19	0.13	354.54	371.82	0.006
2	2	0	2	2	2	9	44.99	6.71	28.45	5.28	0.16	419.76	443.48	0.006
1	0	0	0	2	0	6	47.32	6.88	21.12	5.01	0.12	658.71	665.56	0.006
0	1	0	2	2	1	4	47.19	6.87	21.72	5.19	0.12	382.38	396.14	0.006
0	1	1	1	2	1	2	44.63	6.68	30.13	5.52	0.17	395.91	409.73	0.006
2	2	0	0	1	1	3	44.74	6.69	30.14	5.52	0.17	369.94	383.76	0.006
1	2	0	0	1	1	8	45.50	6.75	30.09	5.54	0.15	387.03	397.33	0.005
1	2	0	2	0	2	8	45.04	6.71	31.86	5.75	0.16	362.64	383.45	0.005
2	1	0	0	1	0	7	47.96	6.93	21.99	5.26	0.11	449.61	459.94	0.005
2	2	0	0	0	1	10	45.72	6.76	31.31	5.69	0.15	357.63	371.50	0.005
2	2	0	1	0	1	8	45.72	6.76	31.68	5.73	0.15	360.29	377.63	0.005
0	1	0	1	2	1	2	46.04	6.79	30.72	5.62	0.14	409.99	420.35	0.005

2	2	0	0	0	2	10	46.00	6.78	31.06	5.68	0.15	359.47	376.81	0.005
1	2	0	0	1	1	10	46.78	6.84	29.64	5.52	0.13	374.14	384.42	0.004
2	2	0	1	0	2	10	46.78	6.84	31.15	5.71	0.13	361.38	382.19	0.004
2	2	0	2	0	0	10	46.79	6.84	31.20	5.72	0.13	359.40	376.74	0.004
2	2	0	1	0	0	10	46.79	6.84	31.44	5.74	0.13	357.49	371.36	0.004
2	2	0	2	0	1	10	46.87	6.85	31.19	5.72	0.13	361.39	382.19	0.004
2	2	0	1	0	1	10	46.93	6.85	31.22	5.72	0.13	359.39	376.73	0.004
2	1	1	0	2	1	7	49.42	7.03	22.34	5.35	0.08	462.98	480.03	0.004
2	1	0	0	2	1	7	49.73	7.05	22.39	5.36	0.08	469.52	483.17	0.003
2	2	0	0	1	1	8	48.23	6.94	31.03	5.72	0.10	381.43	395.17	0.003
0	2	0	1	1	2	12	49.00	7.00	30.99	5.72	0.09	435.13	448.79	0.003
2	2	0	0	1	1	9	49.79	7.06	32.27	5.90	0.08	364.72	378.43	0.002
0	0	0	0	2	0	3	50.61	7.11	27.08	5.48	0.06	781.46	784.92	0.002
2	2	0	2	1	1	4	50.59	7.11	31.53	5.84	0.06	373.20	393.91	0.002
0	2	0	0	2	1	11	51.65	7.19	22.11	5.40	0.04	594.76	601.50	0.002
2	2	0	2	0	2	8	50.78	7.13	34.29	6.19	0.06	353.97	378.25	0.002
0	2	1	0	2	1	4	51.26	7.16	29.30	5.58	0.05	500.56	510.86	0.002
1	1	0	1	2	0	11	52.01	7.21	23.14	5.45	0.03	548.11	558.24	0.001
2	2	0	0	0	1	8	51.25	7.16	33.24	6.06	0.05	358.42	372.30	0.001
0	0	0	1	2	0	3	52.14	7.22	22.22	5.11	0.03	708.71	715.61	0.001
1	2	0	0	2	2	5	51.51	7.18	31.58	5.86	0.04	410.58	424.28	0.001
2	1	0	1	2	1	5	52.42	7.24	22.59	5.47	0.03	390.50	407.65	0.001
1	1	0	1	2	1	2	52.43	7.24	32.49	6.00	0.03	401.46	415.28	0.001
2	2	0	1	0	0	8	52.46	7.24	33.53	6.13	0.03	358.71	372.58	0.001
1	2	0	0	1	1	2	52.59	7.25	32.40	5.99	0.02	374.92	385.30	0.001
2	2	0	2	1	0	11	53.09	7.29	24.75	4.99	0.01	420.89	437.99	0.001
2	2	0	0	1	1	2	52.87	7.27	32.57	6.02	0.02	369.27	383.11	0.001
0	1	0	2	1	0	4	53.18	7.29	23.03	5.54	0.01	360.59	370.96	0.001
1	1	1	1	2	1	5	53.20	7.29	22.74	5.51	0.01	390.53	407.67	0.001
2	2	0	1	2	2	5	53.31	7.30	30.86	5.81	0.01	405.29	425.84	0.000
1	2	0	1	2	2	5	53.64	7.32	31.29	5.87	0.00	411.50	428.62	0.000
2	2	1	1	2	1	7	53.72	7.33	22.80	5.54	0.00	433.62	454.07	0.000

9. APÊNDICE B

Parâmetros dentro dos critérios para o café utilizando ARIMA

p	d	q	mse	rmse	mape	mae	r2	aic	bic	r2/MAPE
7	4	2	14.81	3.85	14.21	2.93	0.72	347.71	382.30	0.051
7	3	3	13.87	3.72	14.77	2.88	0.74	335.64	373.74	0.050
10	4	7	15.06	3.88	14.38	2.96	0.72	362.01	424.28	0.050
10	3	7	15.13	3.89	14.36	2.91	0.72	351.78	414.13	0.050
6	3	2	14.65	3.83	14.59	2.91	0.73	341.67	372.85	0.050
12	4	8	15.45	3.93	14.34	2.98	0.71	355.26	427.91	0.050
5	3	1	13.52	3.68	15.08	2.90	0.75	340.07	364.31	0.050
11	4	8	14.70	3.83	14.74	2.93	0.73	365.42	434.61	0.049
11	4	7	16.08	4.01	14.44	3.04	0.70	359.40	425.14	0.049
5	2	0	15.12	3.89	14.82	2.93	0.72	330.73	351.54	0.049
12	4	7	17.28	4.16	14.01	3.04	0.68	359.05	428.24	0.048
0	3	1	13.53	3.68	15.45	2.93	0.75	418.44	425.37	0.048
6	4	3	14.62	3.82	15.14	2.94	0.73	358.39	392.98	0.048
8	3	3	16.48	4.06	14.45	2.97	0.69	332.84	374.40	0.048
6	3	1	16.57	4.07	14.46	2.97	0.69	338.44	366.15	0.048
10	4	6	16.03	4.00	14.87	2.99	0.70	353.31	412.12	0.047
8	4	4	15.76	3.97	14.99	2.98	0.71	348.80	393.77	0.047
10	4	5	16.87	4.11	14.61	3.10	0.69	350.57	405.92	0.047
8	3	5	13.42	3.66	15.98	2.97	0.75	344.91	393.40	0.047
9	4	6	15.04	3.88	15.49	2.98	0.72	355.32	410.68	0.047
9	4	4	17.28	4.16	14.67	3.13	0.68	344.94	393.38	0.046
0	2	0	16.63	4.08	15.08	3.01	0.69	411.71	415.18	0.046
12	5	6	19.25	4.39	14.05	2.97	0.64	371.49	437.14	0.046
10	4	3	19.99	4.47	14.40	3.22	0.63	346.60	395.04	0.044
4	2	0	13.90	3.73	17.22	3.10	0.74	341.81	359.15	0.043
12	4	3	20.34	4.51	14.45	3.25	0.62	349.96	405.31	0.043
6	2	0	19.53	4.42	14.99	3.17	0.64	328.85	353.12	0.043
11	4	5	19.54	4.42	15.04	3.31	0.64	352.43	411.25	0.042
9	3	7	15.16	3.89	17.37	3.14	0.72	356.00	414.89	0.041
11	4	3	21.34	4.62	14.68	3.30	0.60	348.77	400.67	0.041
10	4	9	23.56	4.85	13.94	2.98	0.56	352.76	421.95	0.040
11	4	6	21.74	4.66	15.27	3.09	0.60	357.40	419.67	0.039
7	3	1	21.94	4.68	15.41	3.36	0.59	330.17	361.35	0.038
8	4	5	20.58	4.54	16.07	3.13	0.62	356.86	405.29	0.038
10	4	8	19.78	4.45	16.74	3.17	0.63	367.53	433.27	0.038
5	4	2	18.76	4.33	17.51	3.21	0.65	357.34	385.02	0.037
3	5	11	22.59	4.75	15.67	3.62	0.58	373.41	425.24	0.037
9	4	3	22.51	4.74	15.82	3.53	0.58	351.80	396.78	0.037
10	4	4	23.90	4.89	15.74	3.52	0.56	342.98	394.88	0.035
4	3	1	17.92	4.23	19.13	3.38	0.67	350.66	371.44	0.035
11	3	7	24.62	4.96	15.93	3.57	0.54	338.81	404.62	0.034

7	4	4	23.13	4.81	17.32	3.31	0.57	350.98	392.50	0.033
12	4	6	25.40	5.04	16.04	3.63	0.53	355.99	421.72	0.033
8	3	2	25.38	5.04	16.34	3.66	0.53	330.48	368.58	0.032
7	2	0	25.91	5.09	16.69	3.72	0.52	320.16	347.90	0.031
4	5	8	26.44	5.14	16.46	3.74	0.51	380.50	425.42	0.031
8	3	1	26.31	5.13	16.64	3.74	0.51	330.74	365.37	0.031
9	4	2	27.05	5.20	16.31	3.75	0.50	342.38	383.90	0.030
9	3	3	26.79	5.18	16.70	3.77	0.50	328.91	373.94	0.030
3	2	0	19.75	4.44	21.24	3.67	0.63	348.99	362.86	0.030
8	4	6	27.52	5.25	18.69	3.59	0.49	374.30	426.19	0.026
9	4	7	27.50	5.24	19.68	3.72	0.49	364.54	423.36	0.025
11	5	6	31.70	5.63	16.58	3.44	0.41	376.20	438.40	0.025
10	3	4	30.77	5.55	17.75	4.08	0.43	332.39	384.35	0.024
8	2	0	30.59	5.53	17.90	4.08	0.43	320.55	351.77	0.024
0	5	8	30.73	5.54	18.23	4.25	0.43	368.64	399.74	0.024
11	4	4	31.55	5.62	17.73	4.12	0.41	341.42	396.77	0.023
1	5	5	31.75	5.63	17.70	4.12	0.41	373.33	397.52	0.023
4	3	2	25.33	5.03	22.91	4.09	0.53	359.63	383.88	0.023
1	5	11	32.16	5.67	17.54	4.14	0.40	373.40	418.32	0.023
2	4	1	22.05	4.70	26.01	4.14	0.59	494.18	508.02	0.023
0	5	9	33.33	5.77	16.91	3.78	0.38	368.59	403.15	0.023
5	3	3	26.26	5.12	23.36	4.18	0.51	354.21	385.39	0.022
1	5	12	35.38	5.95	15.90	3.47	0.34	375.46	423.83	0.022
0	5	12	34.49	5.87	18.35	4.30	0.36	371.65	416.57	0.020
1	2	0	27.61	5.25	25.39	4.45	0.49	365.26	372.20	0.019
3	5	10	36.17	6.01	18.38	4.35	0.33	372.83	421.20	0.018
2	2	0	28.93	5.38	25.94	4.56	0.46	359.04	369.44	0.018
3	3	1	31.78	5.64	25.73	4.64	0.41	357.44	374.76	0.016
3	5	12	38.16	6.18	18.84	4.50	0.29	371.66	426.94	0.015
11	3	4	38.41	6.20	19.67	4.63	0.29	328.08	383.50	0.015
3	4	5	41.96	6.48	16.59	3.72	0.22	345.71	376.84	0.013
10	5	6	40.15	6.34	19.38	3.99	0.25	376.13	434.87	0.013
6	5	11	41.44	6.44	19.90	4.74	0.23	374.27	436.46	0.012
4	3	3	37.38	6.11	27.67	5.04	0.31	369.85	397.56	0.011
12	3	3	42.21	6.50	20.56	4.88	0.22	324.65	380.07	0.011
0	5	4	43.78	6.62	20.49	4.86	0.19	369.47	386.75	0.009
1	6	6	43.69	6.61	20.87	4.92	0.19	405.64	433.25	0.009
9	3	1	43.76	6.61	20.89	4.97	0.19	323.96	362.07	0.009
10	3	1	44.18	6.65	20.98	5.00	0.18	325.96	367.53	0.009
9	3	2	44.59	6.68	21.07	5.03	0.17	325.96	367.52	0.008
8	4	7	42.83	6.54	25.47	4.87	0.20	371.57	426.93	0.008
3	3	3	41.85	6.47	29.17	5.33	0.22	376.03	400.28	0.008
10	3	3	45.29	6.73	21.20	5.07	0.16	323.84	372.33	0.007
7	5	11	46.91	6.85	17.76	3.92	0.13	389.20	454.85	0.007
11	3	3	47.06	6.86	21.63	5.18	0.13	323.74	375.70	0.006

11	3	2	47.20	6.87	21.60	5.18	0.12	322.98	371.48	0.006
9	2	0	47.42	6.89	21.75	5.20	0.12	313.38	348.06	0.005
11	3	1	48.19	6.94	21.86	5.24	0.10	327.44	372.47	0.005
10	2	0	48.22	6.94	21.92	5.25	0.10	315.36	353.51	0.005
12	4	5	49.29	7.02	21.91	5.28	0.08	341.62	403.89	0.004
7	4	7	49.58	7.04	21.87	5.29	0.08	349.55	401.44	0.004
1	3	1	48.19	6.94	31.11	5.72	0.10	372.91	383.30	0.003
12	3	4	50.01	7.07	22.18	5.34	0.07	326.06	384.94	0.003
2	3	1	48.74	6.98	31.36	5.77	0.09	367.05	380.90	0.003
2	3	2	48.78	6.98	31.29	5.76	0.09	376.86	394.18	0.003
10	3	2	51.54	7.18	22.49	5.43	0.04	321.49	366.52	0.002
11	2	0	52.39	7.24	22.77	5.49	0.03	316.75	358.37	0.001
9	2	5	53.92	7.34	22.90	5.55	0.00	326.62	378.64	0.000

Parâmetros dentro dos critérios para a soja utilizando ARIMA

p	d	q	mse	rmse	mape	mae	r2	aic	bic	r2/MAPE
11	6	12	80,333	283	12	244	0.89	2,682	2,765	0.07
6	6	11	137,649	371	14	313	0.81	2,722	2,784	0.06
5	6	12	194,159	441	13	350	0.73	2,707	2,769	0.05
12	4	8	181,877	426	15	348	0.75	2,623	2,696	0.05
1	5	8	224,804	474	14	371	0.69	2,670	2,704	0.05
2	5	9	205,810	454	15	370	0.71	2,670	2,712	0.05
5	5	12	228,805	478	14	368	0.68	2,648	2,711	0.05
6	4	5	166,239	408	16	356	0.77	2,620	2,661	0.05
3	5	11	229,209	479	14	360	0.68	2,679	2,731	0.05
7	4	6	196,398	443	16	382	0.73	2,619	2,668	0.05
11	4	5	192,107	438	16	356	0.73	2,619	2,678	0.04
3	5	9	251,101	501	15	392	0.65	2,678	2,723	0.04
11	4	12	232,914	483	15	373	0.67	2,620	2,703	0.04
9	4	8	223,553	473	16	384	0.69	2,614	2,676	0.04
7	4	3	224,117	473	16	398	0.69	2,606	2,645	0.04
1	5	11	245,185	495	16	399	0.66	2,658	2,702	0.04
6	4	2	231,341	481	16	405	0.68	2,602	2,634	0.04
11	4	8	261,851	512	15	407	0.63	2,614	2,683	0.04
2	5	6	252,960	503	16	407	0.65	2,694	2,725	0.04
11	4	6	223,393	473	17	372	0.69	2,617	2,679	0.04
7	4	4	239,542	489	16	414	0.67	2,598	2,640	0.04
9	4	5	258,515	508	16	415	0.64	2,619	2,671	0.04
6	4	3	245,427	495	16	416	0.66	2,607	2,642	0.04
8	3	4	231,098	481	17	420	0.68	2,594	2,639	0.04
9	4	10	257,953	508	16	421	0.64	2,613	2,682	0.04
9	4	12	276,335	526	16	423	0.61	2,603	2,680	0.04
11	4	4	265,557	515	16	423	0.63	2,605	2,661	0.04
1	5	9	291,557	540	15	422	0.59	2,632	2,670	0.04

9	3	5	240,396	490	17	426	0.66	2,596	2,648	0.04
6	3	4	245,798	496	18	432	0.66	2,602	2,640	0.04
1	5	10	315,955	562	15	381	0.56	2,640	2,681	0.04
10	5	10	327,572	572	15	391	0.54	2,646	2,718	0.04
11	5	11	335,147	579	15	406	0.53	2,644	2,723	0.04
5	4	3	288,766	537	17	446	0.60	2,611	2,642	0.03
7	5	7	344,193	587	15	396	0.52	2,663	2,715	0.03
10	4	11	335,444	579	16	455	0.53	2,612	2,688	0.03
4	4	2	308,706	556	18	459	0.57	2,607	2,631	0.03
8	4	5	316,303	562	17	459	0.56	2,619	2,667	0.03
7	3	5	296,729	545	18	463	0.59	2,599	2,644	0.03
12	4	5	330,786	575	17	462	0.54	2,618	2,681	0.03
11	3	7	311,866	558	18	469	0.56	2,601	2,667	0.03
2	7	8	350,369	592	17	412	0.51	2,901	2,939	0.03
11	3	10	318,432	564	18	475	0.56	2,602	2,678	0.03
8	5	7	375,868	613	16	403	0.48	2,655	2,710	0.03
10	3	9	322,990	568	19	479	0.55	2,598	2,667	0.03
6	3	1	336,024	580	18	482	0.53	2,596	2,624	0.03
12	4	9	358,543	599	18	484	0.50	2,614	2,690	0.03
8	4	7	375,703	613	17	479	0.48	2,617	2,672	0.03
12	4	10	390,305	625	16	415	0.45	2,621	2,700	0.03
5	3	1	348,993	591	19	491	0.51	2,597	2,622	0.03
7	3	1	352,420	594	19	494	0.51	2,595	2,626	0.03
9	4	11	377,655	615	18	488	0.47	2,609	2,682	0.03
7	5	6	373,295	611	18	491	0.48	2,635	2,684	0.03
7	3	3	361,723	601	19	498	0.49	2,591	2,629	0.03
6	2	0	359,759	600	19	499	0.50	2,596	2,620	0.03
8	3	1	364,372	604	19	498	0.49	2,593	2,628	0.03
9	3	1	374,562	612	19	504	0.48	2,594	2,632	0.03
7	2	0	369,616	608	19	506	0.48	2,595	2,623	0.03
8	3	3	391,965	626	18	502	0.45	2,569	2,610	0.03
5	2	0	373,883	611	19	509	0.48	2,598	2,618	0.02
12	3	9	380,973	617	19	513	0.47	2,603	2,679	0.02
11	3	9	388,707	623	19	515	0.46	2,601	2,674	0.02
8	2	0	391,696	626	19	518	0.45	2,593	2,624	0.02
9	3	2	402,127	634	19	521	0.44	2,595	2,637	0.02
9	2	0	405,758	637	19	525	0.43	2,594	2,629	0.02
6	3	2	409,393	640	19	526	0.43	2,590	2,621	0.02
8	3	2	418,043	647	19	531	0.42	2,593	2,631	0.02
7	3	2	420,959	649	20	534	0.41	2,592	2,626	0.02
6	3	3	425,721	652	20	536	0.41	2,591	2,626	0.02
11	4	11	442,673	665	19	535	0.38	2,618	2,698	0.02
1	5	5	460,900	679	19	538	0.36	2,605	2,630	0.02
4	3	1	447,322	669	20	551	0.38	2,600	2,621	0.02
9	5	9	507,471	712	17	450	0.29	2,650	2,716	0.02

3	5	8	493,453	702	19	475	0.31	2,672	2,713	0.02
12	4	3	488,957	699	19	552	0.32	2,595	2,650	0.02
4	2	0	478,879	692	21	571	0.33	2,600	2,618	0.02
9	4	6	492,511	702	20	565	0.31	2,617	2,673	0.02
11	4	3	503,536	710	20	564	0.30	2,590	2,642	0.02
11	4	10	508,895	713	20	569	0.29	2,615	2,691	0.01
10	4	10	508,074	713	21	577	0.29	2,619	2,692	0.01
7	3	4	534,533	731	21	597	0.25	2,594	2,636	0.01
8	3	6	546,118	739	21	602	0.24	2,597	2,649	0.01
9	3	6	548,909	741	21	604	0.23	2,599	2,654	0.01
5	3	2	550,798	742	22	606	0.23	2,601	2,628	0.01
5	5	11	579,223	761	18	486	0.19	2,660	2,719	0.01
6	4	4	560,196	748	21	605	0.22	2,605	2,643	0.01
12	4	6	567,121	753	21	601	0.21	2,611	2,677	0.01
10	4	9	564,785	752	21	606	0.21	2,618	2,687	0.01
0	5	4	565,316	752	21	529	0.21	2,605	2,622	0.01
11	4	7	603,497	777	22	623	0.16	2,615	2,680	0.01
8	3	5	605,155	778	22	631	0.15	2,595	2,644	0.01
8	4	4	617,724	786	20	514	0.14	2,612	2,657	0.01
4	5	9	618,900	787	20	524	0.14	2,667	2,715	0.01
5	4	8	616,453	785	22	627	0.14	2,610	2,658	0.01
9	3	4	619,568	787	22	637	0.13	2,597	2,646	0.01
2	5	12	633,653	796	21	618	0.12	2,646	2,698	0.01
10	3	7	628,038	792	22	643	0.12	2,601	2,664	0.01
3	5	10	644,360	803	19	499	0.10	2,679	2,728	0.01
12	3	1	646,352	804	22	643	0.10	2,577	2,626	0.00
12	3	2	646,516	804	22	643	0.10	2,580	2,632	0.00
11	3	1	662,100	814	22	651	0.08	2,577	2,622	0.00
11	3	2	663,491	815	22	652	0.07	2,579	2,628	0.00
10	5	9	678,158	824	19	518	0.05	2,647	2,716	0.00
12	2	0	684,457	827	23	662	0.04	2,576	2,621	0.00
10	3	1	691,488	832	23	664	0.03	2,577	2,618	0.00
4	4	9	699,366	836	21	642	0.02	2,615	2,664	0.00
11	2	0	699,551	836	23	669	0.02	2,577	2,618	0.00
8	3	7	707,360	841	24	680	0.01	2,599	2,654	0.00
4	5	10	721,914	850	22	571	-0.01	2,654	2,706	0.00
5	5	5	722,454	850	23	683	-0.01	2,630	2,669	0.00
10	2	0	726,699	852	23	681	-0.01	2,576	2,614	0.00
6	4	7	727,472	853	21	547	-0.02	2,619	2,667	0.00
9	4	9	737,581	859	24	692	-0.03	2,614	2,679	0.00
10	4	6	770,476	878	25	631	-0.08	2,619	2,678	0.00
9	3	7	769,599	877	24	707	-0.07	2,600	2,659	0.00
12	4	7	769,541	877	24	607	-0.07	2,615	2,684	0.00
12	3	3	769,131	877	24	698	-0.07	2,582	2,637	0.00
0	4	3	773,261	879	24	702	-0.08	2,585	2,598	0.00

0	4	11	780,350	883	24	706	-0.09	2,619	2,661	0.00
4	3	2	795,473	892	25	720	-0.11	2,600	2,624	0.00

10. APÊNDICE C

Parâmetros dentro dos critérios para o minério de ferro utilizando LSTM

epochs	batch_size	units	mse	rmse	mape	mae	r2	r2/MAPE
150	100	200	2	1	18	1	1	0.029
250	100	200	4	2	23	2	0	0.001

Parâmetros dentro dos critérios para a soja utilizando LSTM

epochs	batch_size	units	mse	rmse	mape	mae	r2	r2/MAPE
250	100	250	26,729	163	5	133	1	0.198
200	100	250	27,299	165	5	125	1	0.198
200	100	150	28,395	169	5	128	1	0.195
150	50	250	31,338	177	5	144	1	0.179
250	150	250	37,085	193	5	143	1	0.176
150	50	150	34,780	186	5	144	1	0.175
200	150	250	33,614	183	6	143	1	0.171
250	100	150	40,924	202	6	162	1	0.161
250	150	200	40,271	201	6	156	1	0.159
200	150	200	45,791	214	6	158	1	0.158
150	150	150	58,239	241	7	186	1	0.135
250	100	200	54,328	233	7	187	1	0.134
150	150	200	62,668	250	7	190	1	0.128
200	50	250	65,499	256	7	200	1	0.128
250	150	150	77,907	279	7	190	1	0.127
150	100	250	57,004	239	7	194	1	0.125
150	150	250	66,499	258	7	198	1	0.124
200	150	150	78,646	280	7	204	1	0.121
150	100	200	66,464	258	7	201	1	0.121
200	100	200	66,102	257	7	208	1	0.121
150	100	150	67,378	260	8	203	1	0.116
250	50	250	94,963	308	8	222	1	0.112
150	50	200	76,178	276	8	222	1	0.112
200	50	200	96,077	310	9	247	1	0.099
250	50	200	110,681	333	8	252	1	0.098
200	50	150	163,361	404	12	341	1	0.063
250	50	150	192,394	439	11	337	1	0.062

Parâmetros dentro dos critérios para o café utilizando LSTM

epochs	batch_size	units	mse	rmse	mape	mae	r2	r2/MAPE
250	50	250	2	1	5	1	1	0.199
250	100	250	2	1	5	1	1	0.194
250	50	150	2	1	5	1	1	0.194
200	50	200	2	1	5	1	1	0.195
150	50	150	2	1	5	1	1	0.188
200	50	250	2	1	5	1	1	0.180
250	100	150	2	1	5	1	1	0.187
200	100	250	2	1	5	1	1	0.178
250	50	200	2	2	5	1	1	0.173
250	100	200	3	2	6	1	1	0.165
250	150	200	3	2	6	1	1	0.153
250	150	150	3	2	6	1	1	0.144
200	100	200	3	2	7	1	1	0.139
200	100	150	4	2	7	1	1	0.136
150	100	200	4	2	7	1	1	0.140
150	50	200	4	2	7	2	1	0.124
200	50	150	4	2	7	2	1	0.132
150	100	150	5	2	8	2	1	0.108
200	150	150	5	2	8	2	1	0.109
250	150	250	6	2	8	2	1	0.106
150	50	250	6	2	8	2	1	0.106
150	100	250	6	3	9	2	1	0.101
200	150	200	8	3	9	2	1	0.091
150	150	200	8	3	10	2	1	0.085
150	150	250	9	3	10	2	1	0.079
200	150	250	10	3	11	2	1	0.074
150	150	150	14	4	12	3	1	0.057

11. APÊNDICE D

Grid search para a busca dos melhores parâmetros para o SARIMA, ARIMA e LSTM, respectivamente.

```
p_values_sarima = []
d_values_sarima = []
q_values_sarima = []
P_values = []
D_values = []
Q_values = []
S_values = []
mse_values_sarima = []
rmse_values_sarima = []
mae_values_sarima = []
mape_values_sarima = []
r2_values_sarima = []
aic_values_sarima = []
bic_values_sarima = []

for p_sarima in range(0, 3):
    for d_sarima in range(0, 3):
        for q_sarima in range(0, 3):
            for P in range(0, 3):
                for D in range(0, 3):
                    for Q in range(0, 3):
                        for S in range(2, 13):
                            if q_sarima * S in range(0, Q * S + 1):

                                try:
                                    sarima_model = sm.tsa.SARIMAX(X_train, order=(p_sarima, d_sarima, q_sarima),
seasonal_order=(P, D, Q, S))
                                    sarima_fit = sarima_model.fit()
                                    predictions_sarima = sarima_fit.predict(start=len(X_train), end=len(df)-1,
typ='levels')

                                    mse_sarima = mean_squared_error(X_test, predictions_sarima)
                                    rmse_sarima = np.sqrt(mse_sarima)
                                    mae_sarima = mean_absolute_error(X_test, predictions_sarima)
                                    mape_sarima = mean_absolute_percentage_error(X_test, predictions_sarima)
                                    r2_sarima = r2_score(X_test, predictions_sarima)
                                    aic_sarima = sarima_fit.aic
                                    bic_sarima = sarima_fit.bic

                                    print(p_sarima, d_sarima, q_sarima, P, D, Q, S, mse_sarima, rmse_sarima, mae_sarima,
mape_sarima, r2_sarima, aic_sarima, bic_sarima)

                                    p_values_sarima.append(p_sarima)
                                    d_values_sarima.append(d_sarima)
                                    q_values_sarima.append(q_sarima)
                                    P_values.append(P)
                                    D_values.append(D)
                                    Q_values.append(Q)
                                    S_values.append(S)
                                    mse_values_sarima.append(mse_sarima)
                                    rmse_values_sarima.append(rmse_sarima)
                                    mae_values_sarima.append(mae_sarima)
                                    mape_values_sarima.append(mape_sarima)
                                    r2_values_sarima.append(r2_sarima)
                                    aic_values_sarima.append(aic_sarima)
                                    bic_values_sarima.append(bic_sarima)

                                except LinAlgError:
                                    print(f"Error for parameters: {p_sarima, d_sarima, q_sarima, P, D, Q, S}")
                                    continue
                                except ValueError:
                                    # Handles other types of specification errors, like overlapping MA lags
                                    print(f"Value Error for parameters: {p_sarima, d_sarima, q_sarima, P, D, Q, S}")
                                    continue

                                else:
                                    pass

print({
    'p': p_values_sarima,
    'd': d_values_sarima,
    'q': q_values_sarima,
    'P': P_values,
    'D': D_values,
    'Q': Q_values,
    'S': S_values,
})
```

```

p_values_arima = []
d_values_arima = []
q_values_arima = []
mse_values_arima = []
rmse_values_arima = []
mae_values_arima = []
mape_values_arima = []
r2_values_arima = []
aic_values_arima = []
bic_values_arima = []

for p_arima in range(0, 13):
    for d_arima in range(0, 13):
        for q_arima in range(0, 13):
            try:
                arima_model = ARIMA(X_train, order=(p_arima, d_arima, q_arima))
                arima_fit = arima_model.fit()
                predictions_arima = arima_fit.predict(start=len(X_train), end=len(df)-1, typ='levels')

                mse_arima = mean_squared_error(X_test, predictions_arima)
                rmse_arima = np.sqrt(mse_arima)
                mae_arima = mean_absolute_error(X_test, predictions_arima)
                mape_arima = mean_absolute_percentage_error(X_test, predictions_arima)
                r2_arima = r2_score(X_test, predictions_arima)
                aic_arima = arima_fit.aic
                bic_arima = arima_fit.bic

                print(p_arima, d_arima, q_arima, mse_arima, rmse_arima, mae_arima, mape_arima, r2_arima,
                    aic_arima, bic_arima)

                p_values_arima.append(p_arima)
                d_values_arima.append(d_arima)
                q_values_arima.append(q_arima)
                mse_values_arima.append(mse_arima)
                rmse_values_arima.append(rmse_arima)
                mae_values_arima.append(mae_arima)
                mape_values_arima.append(mape_arima)
                r2_values_arima.append(r2_arima)
                aic_values_arima.append(aic_arima)
                bic_values_arima.append(bic_arima)

            except LinAlgError:
                print(f"Error for parameters: {p_arima, d_arima, q_arima}")
                continue
            except ValueError:
                # Handles other types of specification errors, like overlapping MA lags
                print(f"Value Error for parameters: {p_arima, d_arima, q_arima}")
                continue

print({
    'p': p_values_arima,
    'd': d_values_arima,
    'q': q_values_arima,
})

```

```

from keras.layers import Dropout
from keras.regularizers import l2
from keras.optimizers import Adam
from keras.callbacks import ReduceLROnPlateau
from keras.callbacks import EarlyStopping

mse_values_LSTM = []
rmse_values_LSTM = []
mae_values_LSTM = []
mape_values_LSTM = []
r2_values_LSTM = []
epoch_values = []
batch_size_values = []
units_values = []

epochs = [150, 200, 250]
batch_sizes = [50, 100, 150]
units_list = [150, 200, 250]

# Grid search
for epoch in epochs:
    for batch_size in batch_sizes:
        for units in units_list:
            print(f"Training with epochs: {epoch}, batch_size: {batch_size}, units: {units}")

            model = Sequential()
            model.add(LSTM(units=units, return_sequences=True, input_shape=(X_train_LSTM.shape[1], 1)))
            model.add(LSTM(units=units, return_sequences=True))
            model.add(LSTM(units=units))
            model.add(Dense(units=1))
            model.compile(optimizer='adam', loss='mean_squared_error')

            model.fit(X_train_LSTM, y_train, epochs=epoch, batch_size=batch_size, verbose=1)

            predictions_LSTM = model.predict(X_test_LSTM)
            predictions_LSTM = scaler.inverse_transform(predictions_LSTM)

            mape_LSTM = mean_absolute_percentage_error(y_test_actual, predictions_LSTM)
            r2_LSTM = r2_score(y_test_actual, predictions_LSTM)
            mse_LSTM = mean_squared_error(y_test_actual, predictions_LSTM)
            rmse_LSTM = np.sqrt(mse_LSTM)
            mae_LSTM = mean_absolute_error(y_test_actual, predictions_LSTM)
            mape_LSTM = mean_absolute_percentage_error(y_test_actual, predictions_LSTM)

            mse_values_LSTM.append(mse_LSTM)
            rmse_values_LSTM.append(rmse_LSTM)
            mae_values_LSTM.append(mae_LSTM)
            mape_values_LSTM.append(mape_LSTM)
            r2_values_LSTM.append(r2_LSTM)
            epoch_values.append(epoch)
            batch_size_values.append(batch_size)
            units_values.append(units)

```