

Inflação no Brasil: uma abordagem via Séries Temporais e Redes Neurais Recorrentes

Nádia G. Biase^{1†}, Julia N. Rodrigues²

¹*Universidade Federal de Uberlândia (UFU).*

²*Bacharel em Estatística. Universidade Federal de Uberlândia (UFU).*

Resumo: *A realização de previsões da inflação é imprescindível quando se deseja melhorar o planejamento estratégico na intenção de reduzir incertezas e aumentar a capacidade de planejamento das famílias, empresas e governo, e assim garantir o bom funcionamento da economia do país. Por conta disso, o objetivo do presente estudo foi realizar previsões do Índice Nacional de Preços ao Consumidos Amplo (IPCA), o qual é a métrica oficial de mensuração da inflação pelo governo federal. As técnicas de Box e Jenkins e de redes neurais recorrentes foram utilizadas para construção de modelos que capturam as informações contidas na série, a fim de avaliar o comportamento da variável analisada ao longo do tempo, bem como efetuar previsões dos valores futuros. Ao aplicar o modelo de Box e Jenkins, foi adotado um modelo de previsão do tipo SARIMA, que considera tanto a tendência como a sazonalidade na série, sendo selecionado aquele com menor erro quadrático médio (RMSE) e menor quantidade de parâmetros. Para os modelos de redes neurais recorrentes, utilizou-se o algoritmo LSTM, e selecionou aquele com menor RMSE. A fim de comparar as duas técnicas de previsão, os critérios adotados foram raiz do erro quadrático médio (RMSE), sendo que o modelo SARIMA se mostrou o melhor modelo para prever 12 meses diretos da inflação, enquanto que para previsões a curto prazo com realimentação, a técnica LSTM se mostrou muito efetiva.*

Palavras-chave: IPCA; Política Monetária; Box & Jenkins; SARIMA; LSTM.

Abstract: *The realization of inflation forecasts is essential when one wants to improve strategic planning in order to reduce uncertainties and increase the planning capacity of families, companies and government, and thus ensure the proper functioning of the country's economy. Because of this, the objective of this study was to make forecasts of the Extended National Consumer Price Index (IPCA), which is the official metric for measuring inflation by the federal government. The Box and Jenkins and recurrent neural network techniques were used to build models that capture the information contained in the series, in order to evaluate the behavior of the variable analyzed over time, as well as to make predictions of future values. By applying the Box and Jenkins model, a SARIMA-type forecasting model was adopted, which considers both the trend and the seasonality in the series, being selected the one with the smallest mean square error (RMSE) and the smallest number of parameters. For the models of recurrent neural networks, the LSTM algorithm was used, and the one with the lowest RMSE was selected. In order to compare the two forecasting techniques, the criteria adopted were root mean square error (RMSE), and the SARIMA model proved to be the best model for predicting 12 direct months of inflation, while for short-term forecasts with feedback, the LSTM technique proved to be very effective.*

Keywords: IPCA; Monetary Policy; Box & Jenkins; SARIMA; LSTM.

[†]Autora correspondente: nadia@famat.ufu.br.

Introdução

Inflação é o nome dado ao aumento dos preços de bens e serviços ao longo do tempo e implica na diminuição do poder de compra da moeda. Ela é calculada pelos índices de preços comumente chamados de índices de inflação. Dois dos mais comumente utilizados são produzidos pelo Instituto Brasileiro de Geografia e Estatística (IBGE): Índice Nacional de Preços ao Consumidor (INPC) e o Índice Nacional de Preços ao Consumidor Amplo (IPCA) (IBGE, 2021). São vários os fatores que podem levar ao aumento destes índices: as pressões de demanda e de custos, a inércia inflacionária e as expectativas de inflação. Dessa forma, o impacto desses índices sobre a economia é grande, visto que gera incertezas, desestimulando o investimento e, assim, prejudicando o crescimento econômico.

O IPCA é o principal indicador utilizado para medir a inflação, sendo este considerado o oficial pelo governo federal. Seu objetivo é mensurar a variação de preços de uma cesta de produtos e serviços consumida pela população. O resultado mostra se os preços aumentaram ou diminuíram de um mês para o outro (IBGE, 2021).

Manter a inflação sob controle, ao redor da meta, é objetivo fundamental do Banco Central (BACEN). A meta para a inflação é estabelecida pelo Conselho Monetário Nacional (CMN) e as taxas de juros são controladas pelo Comitê de Política Monetária do Banco Central (COPOM). O BACEN tem como único e principal objetivo assegurar a estabilidade do poder de compra da moeda e um sistema financeiro sólido e eficiente. A instituição é responsável por executar a estratégia estabelecida pelo CMN para manter a inflação sob controle (BACEN, 2021).

O cenário ideal para a inflação é de valores baixos, estáveis e previsíveis, trazendo vários benefícios para a sociedade, visto que a incerteza na economia é menor, as pessoas podem planejar melhor seu futuro e as famílias não têm sua renda real corroída. Por conta disso, o Brasil adota um sistema de metas para inflação, desde 1999, a fim de controlar esse índice. A meta se refere à inflação acumulada no ano e é definida anualmente no mês de junho, para três anos-calendário à frente, na intenção de reduzir incertezas e melhorar a capacidade de planejamento. O sistema ainda prevê um intervalo de 1,5 pontos percentuais. Ou seja, no caso de 2020 que a meta é 4,00%, o intervalo é de 2,5% à 5,5% (BACEN, 2021). Caso a inflação final estiver fora do intervalo de tolerância, o presidente do BACEN deve divulgar publicamente as razões do descumprimento (ARESTIS et al., 2009).

O Banco Central utiliza a política monetária para alcançar o objetivo de estabilizar os preços, e por consequência preservar o valor do dinheiro, mantendo o poder de compra da moeda. Essa política se refere às ações que visam afetar o custo do dinheiro (taxas de juros) e a quantidade de dinheiro (condições de liquidez) na economia. O principal instrumento utilizado pelo BACEN é a taxa Selic, que por sua vez é definida pelo Comitê de Política Monetária do Banco Central (Copom) a cada 45 dias (MENDONÇA, 2016). Ela se refere à taxa apurada nas operações de empréstimos de um dia entre as instituições financeiras que utilizam títulos públicos federais como garantia. Ela influencia todas as taxas de juros do país, como juros de empréstimos, financiamentos e aplicações financeiras, além de operar por vários canais que acabam por influenciar o comportamento da inflação.

Tendo em vista esse cenário, é substancial a realização de previsões da inflação, a fim de melhorar o planejamento estratégico de famílias, empresas e governo e assim garantir o bom funcionamento da economia do país. Tradicionalmente, existem modelos de acordo com a teoria econômica que são utilizados para realizar previsões, que relacionam alguns índices na influência da variação dos preços de uma economia, sendo eles: taxa de desemprego, taxa de câmbio, taxa de juros e expectativas da inflação. Um exemplo de modelo tradicional é a curva de Phillips (BARBOSA, 2019). Além disso, existem diversas técnicas estatísticas e computacionais capazes de fazer essas estimativas, como por exemplo as técnicas propostas por Box & Jenkins e as técnicas de redes neurais artificiais.

Nas previsões modeladas através de séries temporais, a predição tem por base o estudo dos dados históricos de uma determinada variável de interesse ao longo de um período de tempo. Uma das principais vantagens das análises de modelos de Box & Jenkins se dá por conta de terem inúmeros recursos que podem ser levados em consideração com grande potencial para seleção de um método com melhor desempenho. O autor Bonno (2014) desenvolveu um estudo aplicando modelos sazonais no IPCA e obteve resultados satisfatórios de predição. Por outro lado, o autor Barbosa (2019) também propôs uma análise de previsão da inflação, mas desta vez utilizando modelos ARIMA, desconsiderando a componente sazonal, e comparou os resultados com um modelo de acordo com a teoria econômica.

Com a constante evolução de métodos computacionais e das técnicas de Inteligência Artificial, teve-se como resultado em métodos de Redes Neurais Artificiais (RNA) capazes de prever comportamentos lineares e não lineares. As RNA's têm apresentado excelentes resultados nas previsões de séries temporais, principalmente quando se envolve grandes massas de dados, como em previsões do movimento de ações nas bolsas de valores, por exemplo (DAMETTO, 2018).

Neste contexto, o presente estudo tem como objetivo a modelagem e estimação de valores do índice inflação no Brasil, medido pelo IPCA, através de métodos de séries temporais de Box & Jenkins e modelos de redes neurais artificiais, e dentre estes avaliar os que apresentarem melhores resultados de previsão.

Metodologia

A base de dados utilizada neste trabalho se refere a série histórica mensal correspondente ao Índice de Preços ao Consumidor Amplo (IPCA), obtidos no site do Instituto Brasileiro de Geografia e Estatística (IBGE), através do Sistema IBGE de Recuperação Automática (SIDRA)(SIDRA, 2021).

Considerou-se dois cenários para as análises e previsões, levando em conta fatores externos que podem influenciar diretamente o valor do IPCA:

- **Cenário A:** Período de Dezembro de 1999 a Abril de 2020 para ajustar os modelos e as previsões foram feitas para o período de Maio de 2020 a Abril de 2021 (total de 12 meses de previsão). Neste cenário está contemplado o período em que teve início a pandemia da COVID-19, que gerou impactos relevantes na economia do país.
- **Cenário B:** Período de Dezembro de 1999 a Dezembro de 2018 para ajustar os modelos e as previsões foram feitas para o período de Janeiro de 2019 à Dezembro de 2019 (total de 12 meses de previsão). Para este cenário, desconsiderou-se o período da pandemia da COVID-19, de modo que os dados tivessem menor interferência de fatores externos e permitissem estimar um modelo que se adeque melhor aos valores observados.

Para estimação dos modelos, foi aplicada a técnica de Box & Jenkins para estimação da modelagem SARIMA e a técnica de Redes Neurais Recorrentes, chamada LSTM, para cada cenário citado anteriormente.

Alguns gráficos das séries foram projetados com o auxílio da ferramenta LibreOffice Calc (FOUNDATION, 2021).

Modelagem SARIMA

Com o auxílio do software R, foram realizados os cálculos e a construção dos modelos SARIMA. Optou-se pela utilização de um software livre e com recursos computacionais que apresentam funcionalidades específicas para séries temporais univariadas, especialmente o pacote *forecast*, que auxilia principalmente nas etapas de identificação e estimação dos melhores modelos.

Para uma análise inicial sobre o comportamento da série, foi plotada a série original do valor do IPCA acumulado mensal, para proporcionar uma inspeção visual. Foi realizada também a análise gráfica da função de autocorrelação para averiguar a estacionariedade da série. Na sequência foi plotado um diagrama de dispersão para averiguar a necessidade de uma transformação para estabilizar a variância da série. Em séries econômicas e financeiras, segundo Morettin e Tolo (2006), é comum ocorrer um acréscimo da variância à medida que o tempo passa, e neste caso, os referidos autores recomendam aplicar uma transformação logarítmica.

Para identificar presença de tendência na série, foi utilizado o Coeficiente de Correlação de Spearman, o teste de Wald-Wolfowitz (teste de sequências) e o teste de Cox Stuart (teste do sinal), este último por meio do comando `cox.stuart.test()` pertencente ao pacote `randtests`. Os testes identificaram a presença da tendência, e em função disso, a tendência foi eliminada tomando uma diferença da série, aplicando o comando `diff()`.

Após a tendência ser eliminada aplicou-se o teste de Friedman e o teste de Fisher para averiguar a presença da sazonalidade, com o pacote `stats` e o comando `friedman.test()` e o pacote `GeneCycle` e o comando `fisher.g.test()`, respectivamente, em que ambos confirmaram a sua existência.

Através do comando `auto.arima()` do pacote `forecast`, foram definidos os possíveis modelos para a série temporal. Ao todo, foram testados 15 modelos SARIMA, representados por SARIMA(p, d, q)(P,D,Q). Utilizou-se de técnicas de comparação de modelos para escolher o melhor modelo possível, por meio dos indicadores: Critério de Informação de Akaike (AIC), Critério de Informação Bayesiano (BIC), Raiz Quadrática do Erro Médio (RMSE) e Erro Percentual Médio absoluto (MAPE). Também foi levado como critério de avaliação a existência de parâmetros não significativos, o teste de autocorrelação residual, o teste de Box-Pierce e o teste do periodograma acumulado.

Após a definição dos melhores modelos, fez-se a previsão para $t = 12$ meses, e plotou-se o gráfico da série com os dados estimados e observados. Todos os procedimentos citados foram aplicados nos dois cenários propostos.

LSTM

As simulações de LSTM foram feitas utilizando a linguagem Python (2021), através do Google Colaboratory (2021), que é um ambiente de notebooks Jupyter que não requer configuração e é executado na nuvem. Os pacotes utilizados para as análises foram: pacote Keras, uma biblioteca redes neurais, além das bibliotecas Pandas para estruturação dos dados, Matplotlib para a construção de gráficos, scikit-learn para regressão linear e normalização dos dados e NumPy pela estrutura de vetor e funções matemáticas. A escolha dessa ferramenta se deu por conta de ser um software livre e gratuito, pela grande quantidade de publicações que fazem uso da ferramenta, além de ter uma comunidade ativa que consegue apoiar na solução de problemas. O algoritmo em que foi baseado as análises foi obtido no site Machine Learning Mastery (BROWNLEE, 2021).

Inicialmente, tomou-se uma diferença nos dados para eliminar tendência e torná-los estacionários. Logo após, realizou-se uma transformação escalar nos dados de forma a ficarem entre os valores -1 e 1, por meio do comando `MinMaxScaler` da biblioteca `sklearn`.

Em seguida, ajustou-se um modelo de rede LSTM aos dados de treinamento. Para essa aplicação optou-se por definir um lote de tamanho 1, também chamado de aprendizado online, pois os pesos da rede serão atualizados durante o treinamento após cada padrão de treinamento. A rede utilizou uma função de perda de erro quadrático médio e o algoritmo de otimização ADAM, que melhora funções estocásticas.

A partir dos modelos ajustados, realizou-se as previsões para os últimos 12 meses. Para as análises, adotou-se duas técnicas diferentes para previsão, visto que o objetivo na sequência é comparar o desempenho das RNN frente aos modelos SARIMA. Definimos da seguinte forma:

- **LSTM Sem Reposição:** Neste tipo de modelo, a previsão dos 12 meses será feita de uma só vez a partir de uma entrada t . Para tal, fixamos o número de sequências de saída em 12 (n_{seq}) e o $n_{test} = 1$, sendo esse ponto t o último mês anterior ao período separado para previsão (No cenário A, de Maio/2020 à Abril/2021, e no cenário B de Janeiro/2019 à Dezembro/2019). Desta forma, as saídas se aproximam do formato que temos em modelos SARIMA, tornando mais justa a comparação entre os modelos.
- **LSTM Com Reposição:** Neste tipo de modelo, a previsão terá recorrência mensal, com 1 saída para cada entrada num período de 12 meses. Para tal, fixamos o número de sequências de saída ($n_{seq} = 1$) e o $n_{test} = 12$, sendo esse ponto t o último mês anterior ao período separado para previsão (No cenário A, de Maio/2020 à Abril/2021, e no cenário B de Janeiro/2019 à Dezembro/2019). Neste formato, por ter a reposição dos dados, não se assemelha a forma como estabelecemos nos modelos SARIMA.

Na sequência das previsões, inverteu-se as transformações de escala e diferença realizadas nos dados anteriormente e obteve-se o valor da Raiz Quadrática do Erro Médio (RMSE), para avaliar a acurácia das previsões.

É preciso definir a quantidade de neurônios e a quantidade de épocas a serem adotadas no modelo, porém não está claro na literatura uma regra clara de como estimar essas quantidades. Logo, para o presente trabalho, optou-se por realizar o ajuste dos modelos para as seguintes quantidades de neurônios e épocas:

- **Neurônios:** 7, 25, 50, 100 e 200.
- **Épocas:** 100, 300, 500 e 1000 épocas.

que resultou em 40 combinações de modelos, que foram estimados para cada técnica de previsão (LSTM Com Reposição e LSTM Sem Reposição), obtendo ao final 80 modelos distintos. O critério de seleção do melhor modelo foi a partir do que apresentou o menor valor para o RMSE para cada técnica de previsão.

Comparação entre técnicas

Para comparação entre os melhores modelos propostos por cada técnica (Modelagem SARIMA, LSTM Sem Reposição e LSTM Com Reposição), fez-se uso do cálculo da Raiz Quadrática do Erro Médio (RMSE), de tal forma a escolher aquele que apresentar o menor valor.

Resultados


Cenário A

O gráfico da série histórica mensal do IPCA no período de Dezembro/1999 à Abril/2021 é apresentado na Figura 1. Não fica evidente pela análise gráfica se os dados apresentam sazonalidade. Também pode-se observar que a série é não estacionária, uma vez que apresenta uma tendência negativa, indicando uma queda no valor da inflação nos últimos meses. Além disso, é possível verificar uma alta brusca no nível da série, aproximadamente entre os anos de 2002 e 2003, e no início de 2021. Este último em decorrência da pandemia da COVID-19.

Modelos SARIMA


Inicialmente para as análises de modelos SARIMA, propostos por Box & Jenkins, obteve-se o gráfico da função de autocorrelação (FAC) ilustrado na Figura 2 para identificar graficamente se a série é estacionária. Em caso positivo, o gráfico apresentará um comportamento de decaimento para zero relativamente rápido. Observa-se que não é o caso da série estudada, indicando que os dados não são estacionários.

Figura 1: IPCA acumulado mensal de Dezembro/1999 à Abril/2021



Fonte: Autores.

Figura 2: Função de Autocorrelação da série (Cenário A)



Fonte: Autores.

Na Tabela 1 tem-se o resultado dos testes para tendência. Como hipótese nula dos testes considera-se a não existência de tendência. Desta forma, verificou-se que a hipótese nula foi rejeitada ao nível de significância de 5% para os três testes realizados, sendo necessário realizar uma diferença na série para eliminar a tendência.


Tabela 1: Teste para verificação de tendência na série (Cenário A)

Teste	P-valor	Conclusão
Wald-Wolfowitz	< 0,0000	Rejeita-se H0
Cox-Stuart	0,0027	Rejeita-se H0
Correlação de Spearman	< 0,0000	Rejeita-se H0

Fonte: Autores.


Identificada a tendência, tomou-se uma diferença na série a fim de eliminar esse comportamento e tornar os dados estacionários (Figura 3). Aplicando novamente os testes de tendência, constatou-se a eliminação dessa componente. Ainda na validação da tendência da série diferenciada, é possível examinar pela Figura 4 que as defasagens significativas, na FAC, seguem um padrão, reforçando a escolha pelo ajuste de um modelo do tipo autorregressivo integrado de médias móveis sazonal e o primeiro *lag* significativo na FACp dá sinais da presença do parâmetro regressivo p no modelo.

Figura 3: Série original com uma diferença (Cenário A)



Fonte: Autores.

Figura 4: FAC e FACp da série diferenciada (Cenário A)



Fonte: Autores.

Eliminada a tendência na série, aplicou-se os testes de sazonalidade de Friedman e Fisher na série diferenciada. Como é possível observar na Tabela 2, ambos os testes indicam a existência da componente de sazonalidade, reforçando a necessidade de ajuste de modelos do tipo sazonais.

Posterior a detecção dos componentes de tendência e sazonalidade da série, iniciou-se a etapa de estimação do modelo. Para ajuste dos modelos considerou uma diferença de ordem 1 na série para retirar a tendência. Com auxílio do comando *auto.arima()*, foi proposto 15 modelos, porém, identificado os parâmetros dos modelos propostos, adotou-se como critério inicial de seleção a significância de todos os parâmetros. Para tanto, selecionou-se apenas os modelos 7 (SARIMA(1,1,0)(2,0,0)_[12]), 8 (SARIMA(1,1,0)(1,0,0)_[12]) e 11 (SARIMA(1,1,0)(3,0,0)_[12]). Para estes,

Tabela 2: Teste para verificação de sazonalidade na série (Cenário A)

Teste	P-valor	Conclusão
Friedman	$< 0,0000$	Rejeita-se H_0
Fisher	$< 0,0000$	Rejeita-se H_0

Fonte: Autores.

obteve-se os valores para os critérios de seleção: RMSE, MAPE, AIC e BIC, retratados na Tabela 3.

Tabela 3: Critérios de seleção dos modelos SARIMA propostos (Cenário A)

Modelo	RMSE	MAPE	AIC	BIC
Modelo 7 - SARIMA (1,1,0)(2,0,0) _[12]	2,6727	44,4835	177,4923	191,4810
Modelo 8 - SARIMA(1,1,0)(1,0,0) _[12]	2,5194	41,2266	203,4390	213,9305
Modelo 11 - SARIMA(1,1,0)(3,0,0) _[12]	2,6112	42,5610	167,8535	185,3393

Fonte: Autores.

Para o Modelo 8 (SARIMA(1,1,0)(1,0,0)_[12]) obteve-se os menores valores para o RMSE e o MAPE, enquanto que para o Modelo 11 (SARIMA(1,1,0)(3,0,0)_[12]) os menores valores para o AIC e BIC. Pelo Princípio da Parcimônia, optou-se por adotar o Modelo 8, uma vez que este apresenta uma quantidade menor de parâmetros. Posto isto, os parâmetros estimados são apresentados na Tabela 4.


Tabela 4: Parâmetros estimados do modelo SARIMA (1,1,0)(1,0,0)_[12]

Modelo	Parâmetro	Estimativa	Desvio-Padrão
SARIMA(1,1,0)(1,0,0) _[12]	ϕ_1	0,6452	0,0490
	Φ_1	-0,5142	0,0595

Fonte: Autores.

Para validação da adequabilidade do modelo, foram avaliadas as funções de autocorrelação (FAC) e autocorrelação parcial (FACp) dos resíduos, ilustradas na Figura 5. É possível observar a existência de até 2 lags significativos, indicando que os resíduos são não correlacionados. Para o teste de Box-Pierce, que permite avaliar a hipótese nula de ruído branco para os resíduos, obteve-se o p-valor de 0,5145, concluindo que os resíduos são um processo de ruído branco.


Figura 5: Gráficos de FAC e FACp dos Resíduos (Cenário A)



Fonte: Autores.

Na sequência, validado o modelo proposto, obteve-se as previsões para o período de Maio/2020 à Abril/2021. Os valores obtidos foram representados na Figura 6, comparando-se com os valores observados para o mesmo período. Observa-se que os valores previstos estão bem abaixo dos reais. Isto pode ser justificado por conta da pandemia da COVID-19, que teve seu início em 11 de março de 2020, de acordo com a Organização Mundial de Saúde (OMS, 2021). Por se tratar de uma série econômica, fatores como esse influenciam na acertabilidade do modelo, visto que não se torna fácil a previsão destas situações.

Figura 6: Previsões do modelo SARIMA (Cenário A)



Fonte: Autores.

Em seu estudo, Bonno (2014) propôs um ajuste SARIMA(0,1,1)(1,0,1)_[12] como método de estimação do valor da inflação, no período compreendido entre março de 2003 à março de 2013, reservando o período de abril de 2012 a março de 2013 para validação do modelo. Além disso, comparou os resultados a um modelo estrutural que avalia outras variáveis em função da inflação. Ela concluiu que os resultados obtidos pelo método proposto por Box & Jenkins se mostrou superior ao modelo estrutural, semelhante ao comportamento averiguado no presente estudo.

Modelos LSTM

Assim como proposto na sessão anterior, foram ajustados 40 modelos LSTM diferentes, sendo 20 para modelos do tipo *LSTM Sem Reposição* e 20 para modelos do tipo *LSTM Com Reposição*, na intenção de definir a melhor combinação de neurônios e épocas. Os demais parâmetros e manipulações são dados por:

1. Tomou-se uma diferença nos dados para eliminar tendência e torná-los estacionários;
2. Realizou-se uma transformação escalar nos dados de forma a ficarem entre os valores -1 e 1, através do comando *MinMaxScaler* da biblioteca *sklearn*;
3. Ajustou-se um modelo de rede LSTM aos dados de treinamento com lote de tamanho 1, função de perda de erro quadrático médio e o algoritmo de otimização ADAM;
4. Realizou-se as previsões para o período de Maio/2020 à Abril/2021;
5. Inverteu-se as transformações de escala e diferença realizadas nos dados anteriormente;
6. Obteve-se o valor da Raiz Quadrática do Erro Médio (RMSE)

Os resultados obtidos para cada tipo de aplicação é dado a seguir.

LSTM Sem Reposição

Para este tipo de aplicação, foram testadas as combinações de quantidade de neurônios (7, 25, 50, 100 e 200) e épocas (100, 300, 500 e 1000). Para todos os modelos ajustados, obteve-se o valor do RMSE, a fim de selecionar o modelo com o melhor ajuste. A Tabela 5 apresenta todos os valores para cada combinação. O modelo selecionado foi o LSTM Sem Reposição com 25 Neurônios e 300 Épocas.


Tabela 5: Valores de RMSE para testes variando Neurônios e Épocas em modelos LSTM Sem Reposição (Cenário A)

Neurônios	Épocas			
	100 Épocas	300 Épocas	500 Épocas	1000 Épocas
7	2,765789	3,472479	2,549114	3,223327
25	2,806572	2,548890	2,752101	4,079657
50	3,315780	2,956620	2,991710	3,851407
100	3,463543	2,911312	3,179212	3,651831
200	3,390992	3,216188	3,630765	4,576056

Fonte: Autores.

Definido o modelo mais adequado, projetou-se os valores previstos em um gráfico comparando com os valores reais, que pode ser observado na Figura 7. Ainda sobre a previsão desse modelo, é possível visualizar na Tabela 6 os valores previstos para cada mês no período de Maio/2020 à Abril/2021, comparado aos valores reais e, o respectivo, erro de previsão.

Figura 7: Previsões do modelo LSTM Sem Reposição (Cenário A)



Fonte: Autores.

Como é possível observar, as previsões para o período de Maio/2020 à Abril/2021 não foram muito próximas aos reais, e o erro de previsão tem aumento constante conforme vai passando os meses, da mesma forma que ocorreu nas previsões do modelo SARIMA $(1,1,0)(1,0,0)_{[12]}$.

LSTM Com Reposição

Para esta técnica, ajustou-se os 20 modelos LSTM Com Reposição para as combinações de Neurônios e Épocas listadas anteriormente. Calculou-se o RMSE a fim de definir o melhor ajuste de modelo para este cenário, representados na Tabela 7.

Tabela 6: Previsão realizada utilizando modelo LSTM Sem Reposição (Cenário A)

Período	Valor Real	Valor Previsto	Erro de Previsão
2020-05	1,88	1,84187	0,03813
2020-06	2,13	1,68897	0,44103
2020-07	2,31	1,60720	0,70280
2020-08	2,44	1,58129	0,85871
2020-09	3,14	1,76507	1,37494
2020-10	3,92	1,91536	2,00464
2020-11	4,31	2,00215	2,30785
2020-12	4,52	2,03925	2,48075
2021-01	4,56	2,01254	2,54746
2021-02	5,20	1,87354	3,32646
2021-03	6,10	1,72928	4,37073
2021-04	6,76	2,01792	4,74208

Fonte: Autores.


Tabela 7: Valores de RMSE para testes variando Neurônios e Épocas em modelos LSTM Com Reposição (Cenário A)

Neurônios	Épocas			
	100 Épocas	300 Épocas	500 Épocas	1000 Épocas
7	0,361231	0,404639	0,506719	0,637176
25	0,385922	0,453928	0,636163	0,867946
50	0,429730	0,766542	0,573208	0,856281
100	0,492515	0,797309	1,334063	1,386368
200	0,379334	0,433664	0,538299	0,516772

Fonte: Autores.

Com base nos valores obtidos da raiz quadrática do erro médio, o modelo mais adequado é o LSTM Com Reposição com 7 Neurônios e 100 Épocas. Definido o melhor ajuste, obteve-se um gráfico comparativo dos valores reais e estimados, representado na Figura 8.

Figura 8: Previsões do modelo LSTM Com Reposição (Cenário A)



Fonte: Autores.

Observa-se na Figura 8 que para esse ajuste, os erros de previsão foram baixos, ou seja, os valores estimados se aproximam bastante dos valores reais, comprovando a eficácia de modelos de RNN para estimação de valores a curto prazo.

Comparação entre os Modelos SARIMA e LSTM

Por fim, ao ajustar os modelos por meio dessas técnicas, é preciso estabelecer um critério que avalie qual modelo apresentou melhor desempenho. Para isso, utilizou-se o RMSE de todos os modelos obtidos para eleger o ajuste mais adequado para cada tipo de situação. Na Tabela 8 é possível observar o RMSE para cada um dos melhores modelos selecionados anteriormente.

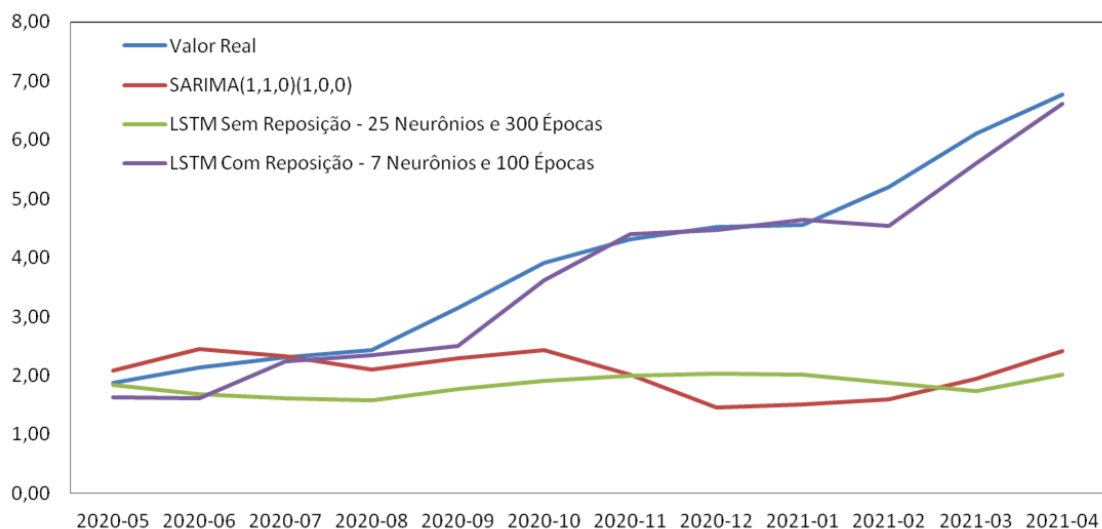
Tabela 8: Valores de RMSE dos modelos selecionados de cada técnica estudada (Cenário A)

Modelo	RMSE
Modelo 8 - SARIMA(1,1,0)(1,0,0)	2,5194
LSTM Sem Reposição - 25 Neurônios e 300 Épocas	2,5489
LSTM Com Reposição - 7 Neurônios e 100 Épocas	0,3612

Fonte: Autores.

Obteve-se também a projeção gráfica das estimativas de todos os modelos selecionados para cada técnica comparados ao valor real da inflação no período de Maio/2020 à Abril/2021, representado na Figura 9.

Figura 9: Série Original e Previsões dos modelos (Cenário A)




Fonte: Autores.

Comparando o RMSE tem-se que o modelo que mais se aproximou dos valores observados é o LSTM Com Reposição - 7 Neurônios e 100 Épocas, porém a técnica deste não é a mesma da técnica dos demais modelos (SARIMA(1,1,0)(1,0,0) e LSTM Sem Reposição - 25 Neurônios e 300 Épocas), os quais buscam definir um modelo que seja capaz de estimar os próximos 12 meses de uma só vez, sem que haja a realimentação de informação. Comparando o modelo SARIMA(1,1,0)(1,0,0) com o LSTM Sem Reposição - 25 Neurônios e 300 Épocas, temos que a técnica proposta por Box & Jenkins (2015) obteve melhores resultados, mesmo que ainda distantes do real.

Cenário B

Tendo em vista o cenário político e econômico vivido no Brasil e no mundo no período da pandemia da COVID-19, os valores da inflação tendem a ser afetados. Por conta disto, buscou-se a estimação de modelos sem a interferência de fatores que não são possíveis de se prever. As análises realizadas neste cenário contemplam o período de Dezembro/1999 à Dezembro/2018, e o período de Janeiro/2019 à Dezembro/2019 separado para validação dos modelos. A Figura 10 ilustra o comportamento dos dados neste intervalo.




Fonte: Autores.

Modelos SARIMA

Primeiramente, obteve-se o gráfico da função de autocorrelação (FAC) ilustrado na Figura 11 para avaliar graficamente se a série estudada apresenta estacionariedade. Constatou-se que a série não possui comportamento de estacionariedade, uma vez que não apresenta um decaimento para zero de forma brusca.

Figura 11: Função de Autocorrelação da série (Cenário B)



Fonte: Autores.

A Tabela 9 apresenta o resultado dos testes para tendência e por meio deles, concluiu-se que a hipótese nula foi rejeitada ao nível de significância de 5% para todos eles. Sendo assim, deve-se tomar uma diferença na série a fim de eliminar a tendência identificada.


Após efetuar a diferença na série, no intuito de eliminar a tendência dos dados e torná-los estacionários, aplicou-se novamente os testes de tendência e pôde constatar a eliminação da componente. A Figura 12 ilustra a série com a primeira diferença. Da mesma forma que no Cenário A, os gráficos da Função de Autocorrelação e Autocorrelação Parcial da série diferenciada, representados pela Figura 13, apresentam um padrão de defasagens significativas, na FAC, e a existência de lags múltiplos de 12 significativos na FACp, reforçando a escolha pelo ajuste de um modelo do tipo SARIMA.

Tabela 9: Teste para verificação de tendência na série (Cenário B)

Teste	P-valor	Conclusão
Wald-Wolfowitz	$< 0,0000$	Rejeita-se H0
Cox-Stuart	$< 0,0000$	Rejeita-se H0
Correlação de Spearman	$< 0,0000$	Rejeita-se H0


Fonte: Autores.

Figura 12: Gráfico da série original com uma diferença (Cenário B).



Fonte: Autores.

Figura 13: Gráficos de FAC e FACp da série diferenciada (Cenário B)



Fonte: Autores.

Em seguida, aplicou-se os testes de sazonalidade de Friedman e Fisher, ambos indicam a existência da componente de sazonalidade, corroborando com a ideia de ajuste de modelos do tipo sazonais.

Em seguida, aplicou-se os testes de sazonalidade de Friedman e Fisher, em ambos indicam a existência da componente de sazonalidade, corroborando com a ideia de ajuste de modelos do tipo sazonais.

Na sequência, iniciou-se a etapa de estimação do modelo. Para ajuste dos modelos, fixou-se o valor de d em 1, uma vez identificado que apenas uma diferença é suficiente para remover a tendência dos dados. Os modelos propostos foram os mesmos utilizados no “Cenário A”, que obtiveram os mesmos resultados de significância dos parâmetros.

Para seleção dos modelos, assim como no Cenário A, adotou-se como critério inicial de seleção a significância de todos os parâmetros. Selecionou-se apenas os modelos 7 (SARIMA(1,1,0)(2,0,0)_[12]), 8 (SARIMA(1,1,0)(1,0,0)_[12]) e 11 (SARIMA(1,1,0)(3,0,0)_[12]). Obteve-se para cada um dos três modelos selecionado os valores para os critérios de seleção: RMSE, MAPE, AIC e BIC, retratados na Tabela 10.

Tabela 10: Critérios de seleção dos modelos SARIMA propostos (Cenário B)

Modelo	RMSE	MAPE	AIC	BIC
Modelo 7 - SARIMA (1,1,0)(2,0,0) _[12]	0,50486	0,10428	161,97090	175,68830
Modelo 8 - SARIMA(1,1,0)(1,0,0) _[12]	0,83247	0,22412	186,61370	196,90170
Modelo 11 - SARIMA(1,1,0)(3,0,0) _[12]	0,90178	0,16533	152,39280	169,53950

Fonte: Autores.

O Modelo 7 (SARIMA(1,1,0)(2,0,0)_[12]) apresentou os menores valores para o RMSE e o MAPE, enquanto que o Modelo 11 (SARIMA(1,1,0)(3,0,0)_[12]) os menores valores para o AIC e BIC. Pelo Princípio da Parcimônia, optou-se por adotar o Modelo 7, visto que este apresenta uma quantidade menor de parâmetros. Os parâmetros estimados são apresentados na Tabela 11.

Tabela 11: Parâmetros estimados do modelo SARIMA (1,1,0)(2,0,0)_[12]

Modelo	Parâmetro	Estimativa	Desvio-Padrão
Modelo 7 - SARIMA (1,1,0)(2,0,0) _[12]	ϕ_1	0,6628	0,0495
	Φ_1	-0,6205	0,0672
	Φ_2	-0,3573	0,0660

Fonte: Autores.

Avaliando as funções de autocorrelação (FAC) e autocorrelação parcial (FACp) residuais, representados na Figura 14, para validação da adequabilidade do modelo, é possível observar a existência de um *lag* significativo na FAC e dois *lags* significativos na FACp, indicando que os resíduos são não correlacionados. Para o teste de Box-Pierce, obteve-se p-valor de 0,8025, constatando que os resíduos são um processo de ruído branco.

Validado o modelo proposto, obteve-se as previsões para o período de Janeiro/2019 à Dezembro/2019. A Figura 15 ilustra os valores obtidos comparado aos valores observados neste mesmo período. Observa-se que os valores previstos estão próximos dos reais, indicando que o modelo ajustável é adequado para previsão do índice de inflação no Brasil. Na Tabela 12, é possível confirmar que os erros de previsões foram relativamente baixos, quando comparados com os resultados do Cenário A.

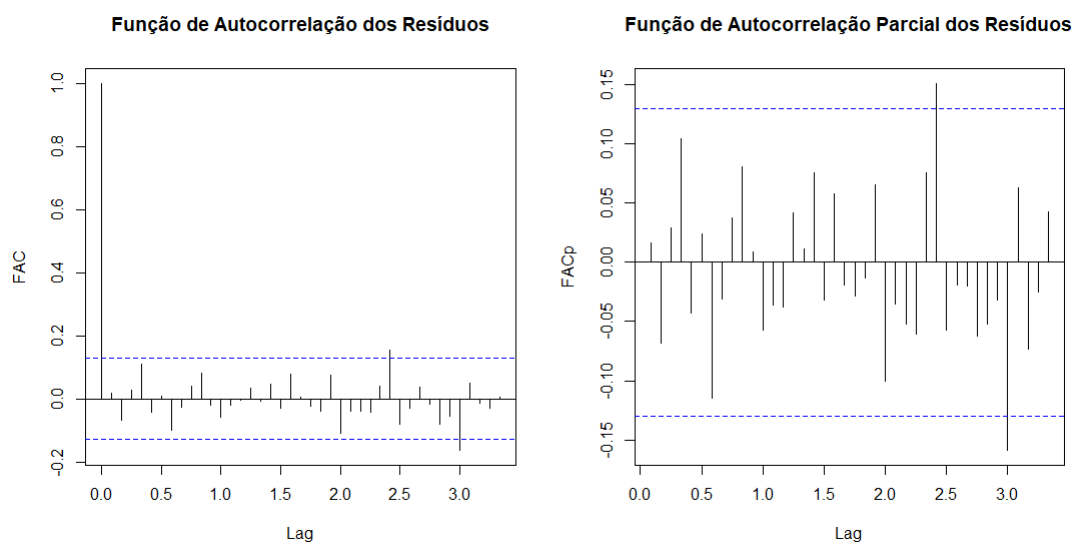
Modelos LSTM

LSTM Sem Reposição

Da mesma forma que realizado anteriormente para o Cenário A, foram ajustados 20 modelos LSTM Sem Reposição variando apenas a quantidade de neurônios e épocas. Obteve-se então os valores do RMSE para cada ajuste, apresentados na Tabela 13. O modelo que apresentou o menor valor foi o LSTM Sem Reposição com 7 Neurônios e 500 Épocas.


Definido o melhor modelo, obteve-se um gráfico com os valores reais e previstos pelo ajuste no período de Janeiro/2019 à Dezembro/2019, representado na Figura 16.

Figura 14: Gráficos de FAC e FACp dos Resíduos (Cenário B).



Fonte: Autores.

Figura 15: Previsões do modelo SARIMA (Cenário B)



Fonte: Autores.

Apesar de apresentar um bom valor para RMSE, bem como erros de previsão relativamente baixos, é possível observar na Figura 16 que os valores previstos estão se comportando quase que de forma linear, levando a questionar a real qualidade do modelo ajustado, visto que pode ter ocorrido algum erro de generalização.

LSTM Com Reposição

Assim como no cenário anterior, ajustou-se os 20 modelos de LSTM Com Reposição, variando as quantidades de neurônios e épocas, e calculando o RMSE a fim de selecionar o melhor modelo entre os ajustados. A Tabela 14 apresenta os resultados obtidos.

O modelo que apresentou o melhor ajuste seguindo o critério estabelecido foi o LSTM Com Reposição com 100 Neurônios e 100 Épocas. Da mesma forma que encontrado no “Cenário A”, a quantidade de épocas foi 100, diferenciando apenas na quantidade de neurônios, que passou de 7 para 100. Esse fator pode ser justificado pelo fato dos dados no período de Janeiro/2019 à Dezembro/2019 apresentarem uma variabilidade menor, comparados ao período de Maio/2020

Tabela 12: Previsão realizada utilizando modelo SARIMA e erro de previsão (Cenário B)

Período	Valor Real	Valor Previsto	Erro de Previsão
2019-01	3,78	3,83878	0,05878
2019-02	3,89	3,86122	0,02879
2019-03	4,58	3,89532	0,68468
2019-04	4,94	3,93255	1,00745
2019-05	4,66	3,98354	0,67646
2019-06	3,37	3,20980	0,16020
2019-07	3,22	3,23189	0,01189
2019-08	3,43	3,48413	0,05413
2019-09	2,89	3,23330	0,34330
2019-10	2,54	3,15005	0,61005
2019-11	3,27	3,42582	0,15582
2019-12	4,31	3,55509	0,75491


Fonte: Autores.

Tabela 13: Valores de RMSE para testes variando Neurônios e Épocas em modelos LSTM Sem Reposição (Cenário B)

Neurônios	Épocas			
	100 Épocas	300 Épocas	500 Épocas	1000 Épocas
7	0,840167	0,874836	0,656259	0,864261
25	0,816595	0,842409	1,016555	0,996567
50	0,873526	0,935319	2,081523	0,834141
100	1,238573	1,465272	1,055164	1,450778
200	1,369546	0,861307	1,019192	1,932660

Fonte: Autores.

Figura 16: Previsões do modelo LSTM Sem Reposição (Cenário B).



Fonte: Autores.

à Abril/2021, necessitando de mais iterações na camada intermediária para conseguir realizar as previsões.


A Figura 17 e a Tabela 15 apresentam detalhadamente os valores previstos comparados aos valores reais do índice de inflação no Brasil.

Tabela 14: Valores de RMSE para testes variando Neurônios e Épocas em modelos LSTM Com Reposição (Cenário B)

Neurônios	Épocas			
	100 Épocas	300 Épocas	500 Épocas	1000 Épocas
7	0,576789	0,562368	0,622436	0,807576
25	0,597113	0,758777	0,557478	0,641260
50	0,595374	0,555143	0,548486	0,567798
100	0,492127	0,588366	0,550778	0,854994
200	0,572863	0,589755	0,848020	0,676575

Fonte: Autores.

Figura 17: Previsões do modelo LSTM Com Reposição (Cenário B).



Fonte: Autores.

Tabela 15: Previsão realizada utilizando modelo LSTM Com Reposição e erro de previsão (Cenário B)

Período	Valor Real	Valor Previsto	Erro de Previsão
2019-01	3,78	3,50740	0,27260
2019-02	3,89	3,77320	0,11680
2019-03	4,58	3,90202	0,67798
2019-04	4,94	4,88349	0,05651
2019-05	4,66	4,88452	0,22452
2019-06	3,37	4,18050	0,81050
2019-07	3,22	2,66190	0,55810
2019-08	3,43	3,17526	0,25474
2019-09	2,89	3,64633	0,75633
2019-10	2,54	2,49550	0,04450
2019-11	3,27	2,59144	0,67856
2019-12	4,31	3,82283	0,48717

Fonte: Autores.

Comparação entre os Modelos SARIMA e LSTM

Por fim, comparou-se os resultados obtidos nas técnicas aplicadas. Na Tabela 16 está representada o valor do RMSE obtido por cada um dos modelos selecionados.

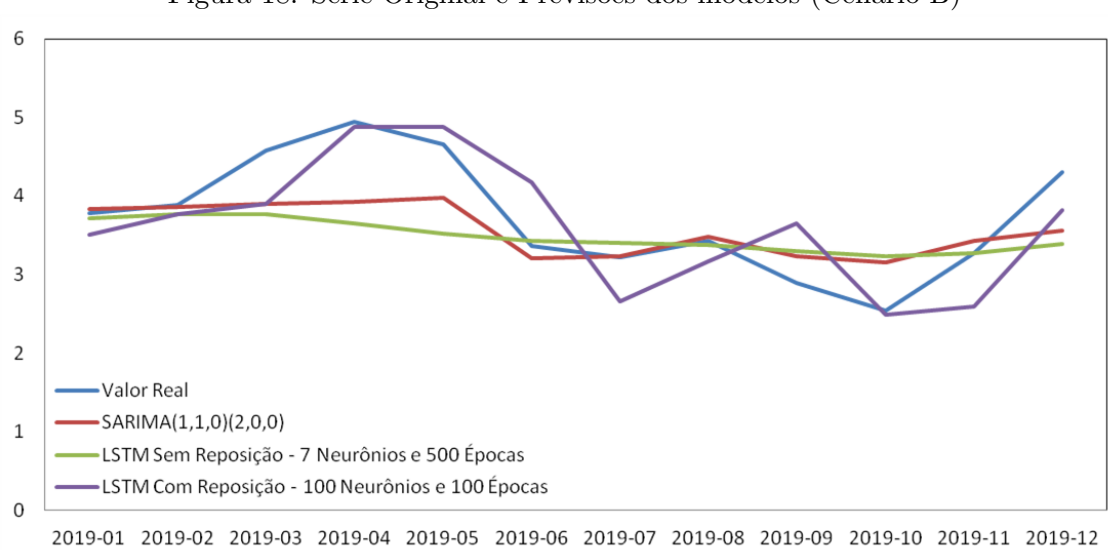
Tabela 16: Valores de RMSE dos modelos selecionados de cada técnica estudada (Cenário B)

Modelo	RMSE
Modelo 7 - SARIMA(1,1,0)(2,0,0)	0,50486
LSTM Sem Reposição - 7 Neurônios e 500 Épocas	0,65626
LSTM Com Reposição - 100 Neurônios e 100 Épocas	0,49213

Fonte: Autores.

Na Figura 18, projetou-se as estimativas de todos os modelos selecionados para cada técnica comparados ao valor real da inflação no período de Janeiro/2019 à Dezembro/2019.

Figura 18: Série Original e Previsões dos modelos (Cenário B)



Fonte: Autores.

Seguindo o critério de seleção do menor valor para o RMSE, tem-se que o modelo que mais se aproximou dos valores observados é o LSTM Com Reposição - 100 Neurônios e 100 Épocas. Comparando os modelos SARIMA(1,1,0)(2,0,0) e LSTM Sem Reposição - 7 Neurônios e 500 Épocas, que apresentam a mesma ideia de estimação de 12 valores de uma só vez, temos que a técnica proposta por Box & Jenkins (2015) obteve melhores resultados, visto que o modelo de RNN apresentou um comportamento de *overtraining*, quando a rede se especializa no conjunto de dados de treinamento por conta da grande quantidade de treinos e perde a capacidade de generalização, indicando que talvez o ajuste não tenha sido adequado.

Discussão

Diante do exposto, a modelagem do índice inflacionário no Brasil pode ser avaliada por meio dos modelos de séries temporais, baseados na metodologia de Bok & Jenkins, bem como via redes neurais recorrentes.

Para garantir a robustez dos modelos nas previsões da inflação foram avaliados dois cenários para a variável em estudo: o primeiro incluindo o período inicial da pandemia da COVID-19 e o segundo desconsiderando esse período da pandemia, tendo em vista que esse período gerou impactos relevantes na economia do país. Sendo assim, verificou que ambas as técnicas

apresentaram resultados mais satisfatórios no segundo cenário, pois as previsões, embora apresentaram algumas oscilações, forneceram valores mais próximos dos observados, reproduzindo a periodicidade e a tendência detectada na série.

Os modelos de séries temporais SARIMA adotados apresentaram um bom ajuste, os pressupostos da análise residual foram todos atendidos e os erros quadráticos médio de previsão (RMSE) foram relativamente pequenos, indicando que esses modelos são adequados para prever a inflação do país. Resultados semelhantes foram encontrados por Bonno (2014) para prever a inflação do país usando a metodologia de Box e Jenkins, decompondo a série por meio da tendência, da sazonalidade e das irregularidades presentes. Os modelos SARIMA ajustados foram apropriados, a implementação dos modelos foi imediata e as previsões foram precisas e obtidas de forma simples e direta.

Avaliando os principais indicadores inflacionários brasileiros e seus reflexos na performance do índice Ibovespa entre os anos de 2010 e 2020, Camargo e Moura (2022) por meio de análises descritivas e séries temporais concluíram que os valores do IPCA sofreram consideráveis aumentos no ano de 2020, em decorrência do COVID-19. Durante a pandemia, muitos setores brasileiros se viram com dificuldades e tiveram que se adaptar frente às restrições sanitárias. No entanto, essa adaptação fez com que estes mesmos setores e seus mercados disparassem e crescessem em meio à crise do país, dentre eles destaca-se o mercado farmacêutico, os aplicativos delivery relacionados a refeições e E-commerce. Desse modo, por conta dessa alta dos valores de IPCA, é que nesse estudo, foi analisado dois cenários, pois os modelos de previsão poderiam apresentar um erro de previsão muito elevado e não condizer com a realidade dos acontecimentos, gerando resultados não satisfatórios, na situação em que os dados do período da pandemia estivessem contidos na análise, o que de fato ocorreu.

Por outro lado, Zaniol et al. (2021) buscando prever a inflação do Brasil por meio da inteligência artificial, verificaram que as previsões obtidas foram suavizadas, não sendo capazes de identificar movimentos transitórios da inflação. Segundo os autores, uma das limitações associadas à análise da inflação é a carência de dados, visto que o Brasil sofreu inúmeras trocas de moedas e de políticas monetárias que dificultam a obtenção de dados dentro de um mesmo contexto e também o esforço computacional que o método exige para obtenção de resultados mais acurados.

Já Martelli (2021), usando modelos LSTM, realizaram uma análise preditiva do preço da soja usando dados climáticos e dados complementares, tais como valor do dólar, a inflação e a produção anual de soja correspondente aos anos de 2000 a 2020 de todo o território nacional. Por meio deste estudo foi possível prever o preço da soja de maneira eficaz, a ponto de auxiliar os agricultores nas tomadas de decisão.

Diante disso, percebe-se que a técnica de redes neurais também é eficiente para avaliar variáveis financeiras, porém, necessita de uma demanda maior de esforço computacional para treinar parte dos dados, a fim de verificar sua capacidade em reconhecer padrões e prever dados desconhecidos. Ademais, pode-se dizer ainda que o não reconhecimento das tendências, em virtude dos movimentos transitórios da inflação, faz com que se busque constantemente o aumento das conexões entre os neurônios, com o intuito de tentar reconhecer padrões nos dados desconhecidos. Portanto, as técnicas baseadas em redes neurais e sistema de inteligência artificial tem sua relevância, e nos últimos tempos, tem sido aplicadas com frequência.

Desse modo, entende-se que o estudo abordado pode ser incrementado com pesquisas e análises que possam dar uma robustez e confiabilidade maior aos modelos e técnicas aplicados. Estudos envolvendo a economia do país são muito importante para a sociedade e investidores, visto que o mercado financeiro tem ganhado cada vez mais espaço nas mídias e cultura das pessoas e podem auxiliar na gestão dos investimentos e aplicações.

Conclusões

Os modelos obtidos pelas técnicas de Box & Jenkins e redes neurais recorrentes se apresentaram úteis para descrever o comportamento do índice de inflação medido pelo IPCA no Brasil. Ao todo, foram escolhidos 6 modelos entre todos os ajustados, para as técnicas SARIMA, LSTM Sem Reposição e LSTM Com Reposição, sendo 3 para cada cenário.

No Cenário A, o modelo SARIMA que apresentou os melhores resultados foi representado pelo SARIMA(1,1,0)(1,0,0)_[12], e para os modelos de RNN foram o LSTM Sem Reposição com 25 neurônios e 300 épocas e o LSTM Com Reposição com 7 neurônios e 100 épocas. Dentre estes, o melhor ajuste foi este último, que apresenta comportamento de realimentação de informações, de forma a tornar as previsões mais acertivas. Apesar deste modelo ter se mostrado adequado, observou-se que fatores externos estariam afetando na estimação, em decorrência da pandemia do COVID-19. Portanto, realizou-se o ajuste de modelos em um período sem a influência deste fenômeno, o qual chamamos de Cenário B.

Para o Cenário B, os melhores modelos foram: SARIMA(1,1,0)(2,0,0)_[12], LSTM Sem Reposição com 7 neurônios e 500 épocas e o LSTM Com Reposição com 100 neurônios e 100 épocas. Neste contexto, o melhor ajuste foi novamente o com reposição de informações. Porém, ao se tratar de modelos que fazem a previsão de 12 meses futuros de uma só vez, o modelo mais qualificado foi o SARIMA, visto que apresentou o segundo menor valor para o RMSE e pelo fato do modelo sem reposição ter apresentado um comportamento de overtraining, que é quando o modelo começa a perder a capacidade de generalizar os valores previstos em decorrência de um número muito grande de treinamento.

Dentre os dois cenários estudados, os melhores resultados obtidos foram para o Cenário B, visto que apresentaram valores de erros de previsão menores do que o Cenário A. Essa conclusão se dá por conta de o segundo cenário estar livre de grandes ruídos externos como é o caso da pandemia da COVID-19, que acaba por ter grande impacto nos valores realizados.

Por fim, conclui-se que quando o objetivo for estimar valores futuros a curto prazo (no máximo 3 meses), a técnica de LSTM se torna uma opção viável, tendo em vista a facilidade do ajuste dos modelos. Por outro lado, se a intenção for fazer uma previsão única a um médio prazo (12 meses), recomenda-se o uso das técnicas propostas por Box & Jenkins, tendo em vista que estes modelos são mais robustos e podem evitar erros de generalização.

Referências

ARESTIS, P.; PAULA, L.F.; FILHO, F.F. A nova política monetária: uma análise do regime de metas de inflação no Brasil. *Economia e Sociedade*, v 18, n. 1, p. 1-30, 2009.

BACEN. *Banco Central do Brasil*, 2021. Disponível em: <https://www.bcb.gov.br/>.

BARBOSA, L.M. Prevendo a Inflação Brasileira: Comparação Entre um Modelo Teórico e um Ateórico de Séries Temporais. *Boletim Informações Fipe*, p. 44-49, 2019.

BONNO, S.J.P. *Previsão de Inflação Utilizando Modelos de Séries Temporais*. Dissertação de Mestrado, 2014.

BROWNLEE, J. *Machine Learning Mastery*, 2021. Disponível em: <https://machinelearningmastery.com/category/lstm/>.

BOX, G.E.P.; JENKINS, G.M.; REINSEL, G.C. *Time Series Analysis: Forecasting and Control*, v1, Wiley, 5ª ed., 2015.

- CAMARGO, D.; MOURA, R.F.S. *Um Estudo Das Séries Temporais Dos Principais Indicadores Inflacionários Brasileiros E Seus Reflexos Na Performance Do Índice Ibovespa*. SocArXiv, 2022. Disponível em: <https://doi.org/10.31235/osf.io/x5w9v>.
- COLABORATORY, G. *Google Colaboratory*, 2021. Disponível em: <https://research.google.com/colaboratory/>
- DAMETTO, R. C. *Estudo da aplicação de redes neurais artificiais para predição de séries temporais financeiras*. Dissertação de Mestrado, 2018.
- FOUNDATION, T. D. *LibreOffice Calc.*, 2021. Disponível em: <https://www.libreoffice.org/discover/calc/>.
- IBGE, *Instituto Brasileiro de Geografia e Estatística*, 2021. Disponível em: <https://www.ibge.gov.br/>.
- MARTELLI, O.P. *Modelos LSTM para predição do preço da soja com base em dados climáticos brasileiros*. 2021, 39p., Monografia- Universidade Tecnológica Federal do Paraná, Pato Branco.
- MENDONÇA, H.F. *Mecanismos de transmissão monetária e a determinação da taxa de juros: uma aplicação da regra de Taylor ao caso brasileiro*. *Economia e Sociedade*, v.10, n.1, p.65-81, 2016.
- MORETTIN, P.A.; TOLOI, C.M. *Análise de Séries Temporais*. São Paulo, Blucher, 2006.
- OMS. *Organização Mundial de Saúde*, 2021. Disponível em: <https://www.who.int/es>.
- PYTHON. *Python Software Foundation*, 2021. Disponível em: <https://www.python.org/>.
- SIDRA, *Sistema IBGE de Recuperação Automática - SIDRA*, 2021, Disponível em: <https://sidra.ibge.gov.br/>.
- R CORE TEAM. *R: A Language and Environment for Statistical Computing*, 2021. Disponível em: <https://www.R-project.org/>.
- ZANIOL, C.; PAZINATTO, C.; SCHILLER, A.P.S.; MORAES, J.C.P. Previsão de inflação com o uso de Inteligência Artificial. *Revista Brasileira de Computação Aplicada*, v. 13, n. 2, p. 96-104, 2021.