



Análise e Previsão da Variação Homóloga do Índice de Preço ao Consumidor Nacional: Aplicação da Metodologia de Box-Jenkins

Bernardo Vaz

Sem vinculação institucional

vazbernardo88@gmail.com

N.º ORCID: 0009-0000-9646-6830

Resumo

Este artigo analisa a previsão da inflação em Angola a partir do Índice de Preços ao Consumidor Nacional (IPCN), calculado pelo INE-Angola. O estudo parte da relevância dos preços como barómetro económico e da necessidade de previsões fiáveis para orientar políticas monetárias e económicas num contexto marcado por volatilidade e fortes impactos sociais. Com base na literatura sobre previsão de inflação, avaliou-se a aplicação da metodologia Box-Jenkins (ARIMA) à série temporal do IPCN. Os resultados mostram que a série apresenta características de estacionaridade, dispensando diferenciação, e que o modelo ARMA (p,q) ajusta-se de forma adequada, com resíduos aleatórios e estatisticamente validados. A previsão revelou elevada precisão, com um MAPE de 1,71% e estatística U^2 de Theil de 0,405, superando previsões simples. As projeções indicam uma desaceleração da inflação entre fevereiro e setembro de 2025, o que sugere algum alívio na subida dos preços e fornece elementos úteis para a formulação de políticas económicas e para as decisões dos agentes económicos.

Palavras-chave: IPCN. Previsão. Inflação. ARIMA. Box-Jenkins

1. Introdução

Os preços funcionam como um barómetro para a economia. A sua previsibilidade é fundamental para que os agentes económicos possam tomar decisões sobre o nível de investimento, a quantidade de estoque, o nível de produção e emprego.

A previsão da inflação é um instrumento crítico para a política económica e monetária, especialmente em economias em desenvolvimento como a de Angola, onde a volatilidade dos preços pode ter impactos sociais profundos. O Índice de Preços ao Consumidor Nacional (IPCN), calculado pelo Instituto Nacional de Estatística de Angola (INE-Angola), serve como base para esta análise. Este artigo revisa cinco obras fundamentais sobre previsão de inflação e propõe a aplicação da metodologia de Box-Jenkins ao IPCN angolano, considerando as particularidades do contexto económico do país.

De acordo com Stock & Watson (1999), a previsão de inflação é crucial para políticas monetárias eficazes, pois ajuda bancos centrais a antecipar tendências e ajustar taxas de juros. Para estes autores, modelos multivariados permitem maior precisão, reduzindo riscos de erros de política económica que podem levar a recessões ou hiperinflação. Atkeson (2001), apresenta uma visão contrária, destacando que, em alguns casos, métodos simples (como usar a inflação passada) podem ser tão úteis quanto modelos complexos, especialmente em contextos de incerteza estrutural.

Marcellino (2008), em um estudo comparativo, procura identificar os modelos mais adequados em diferentes cenários, concluindo, que a escolha do método afeta diretamente a estabilidade económica. Para este autor, modelos como ARIMA (Box-Jenkins) são úteis para decisões de curto prazo, enquanto modelos estruturais (VAR) são essenciais para planeamento de médio prazo.

Para Faust & Wright (2013), as previsões de inflação são a base para expectativas racionais de agentes económicos, influenciando investimentos e consumo. Os autores acrescentam, que a combinação de modelos e o uso de expectativas de mercado melhoram a robustez das previsões, reduzindo surpresas inflacionárias.

Com base no que foi exposto, buscou-se responder a seguinte questão: Qual é o resultado da aplicação do método ARIMA para prever a Variação Homóloga do Índice de Preço ao Consumidor Nacional (IPCN)? Na busca da resposta do problema proposto definiu-se como objetivo geral a análise da previsão da variação homóloga do Índice de Preços ao Consumidor Nacional (IPCN) em Angola, aplicando a metodologia de Box-Jenkins (ARIMA), com vista a melhorar a precisão das previsões de inflação e apoiar a formulação de políticas económicas. Especificamente: a) identificar as características temporais da série histórica do IPCN angolano, através de análise descritiva e testes de estacionaridade; b) aplicar o modelo ARIMA à série do IPCN, selecionando os parâmetros ótimos (p , d , q) com base em critérios de informação (AIC, BIC) e validando o modelo; c) avaliar a capacidade preditiva do modelo para horizontes de 4 e 6 meses, comparando os resultados com as projeções oficiais do INE.

2. Previsão de Inflação

2.1. Modelo Auto Regressivo (AR) e Média Móvel (MA)

Os modelos Auto Regressivos (AR) e Média Móvel (MA) são baseados na suposição de que a série temporal seja gerada através de um sistema linear, e que possuem um termo de erro aleatório não correlacionado, com média zero e variância constante, ou seja, um ruído branco (GUJARATI, 2000).

Para o caso de modelos AR, dada uma série de dados Z_t , esta será descrita por seus valores históricos Z_{t-1} , Z_{t-2} ,... e pelo ruído branco a_t , cuja estrutura apresentada por Morettin e Tolo (2004) é expressa por

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t$$

em que p é a ordem do modelo auto regressivo, denotado por $AR(p)$. De outra forma, o valor de Z no período t , depende do seu valor no p períodos anteriores. Assim, $AR(p)$ é um processo auto-regressivo de p -ésima ordem (GUJARATI, 2000).

Já o modelo MA, além de considerar o termo de erro (ruído branco), considera o valor de uma constante mais uma média móvel dos termos de erro corrente e passado. Assim, conforme Gujarati (2000), Z “no período t é igual a uma constante mais uma média móvel” e “um processo de média móvel é simplesmente uma combinação linear dos termos de erro ruído branco”, cuja ordem é representada por q . Logo, um modelo $MA(q)$ conforme Morettin e Tolo (2004) será notado por

$$Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

Em que $MA(q)$ é um processo de média móvel de ordem q (GUJARATI, 2000).

2.2. Modelagem ARIMA (p, d, q)

Conforme Ediger e Akar (2007), o ARIMA é um dos mais populares modelos para análise da previsão de demanda para séries temporais. Os modelos ARIMA são modelos que utilizam apenas dados históricos de séries temporais com o intuito de expressar como as séries reagem de acordo com a variação estocástica anterior (BABAI et al, 2013). Os modelos ARIMA podem ajudar a entender a dinâmica dos dados em uma determinada aplicação (BABU; REDDY, 2014).

O modelo ARIMA originou-se a partir dos modelos de auto-regressão (AR) e das médias móveis (MA) e da combinação entre AR e MA (modelo ARMA), (GUJARATI, 2000; MORETTIN; TOLLOI, 2004; EDIGER; AKAR, 2007).

Conforme Gujarati (2000) “muitas séries temporais econômicas são não-estacionárias, ou seja, são integrais”. No entanto, dada uma série temporal, se esta for integrada de ordem 1

(I[1]), suas primeiras diferenças serão I[0], ou seja, demonstram-se estacionárias. Assim, em geral, se uma série temporal não estacionária, representada por I[d], se diferenciarmos d vezes esta série, será obtida uma série estacionária I[0] (GUJARATI, 2000). Conforme o autor, didaticamente adota-se I[0] para indicar que a série é estacionária.

Logo, se para análise de uma série temporal for necessária a sua diferenciação d vezes para torná-la estacionária, diz-se que esta série temporal é ARIMA (Auto Regressiva Integrada de Média Móvel). Assim, será representada por ARIMA(p,d,q), onde p indica o número de termos auto-regressivos, d o número de vezes que a série deve ser diferenciada para se tornar estacionária e, q indica o número de termos de média móvel (GUJARATI, 2000). A estrutura do modelo ARIMA é expressa por

$$\Delta^d Z_t = W_t = \phi_1 W_{t-1} + \phi_2 W_{t-2} + \dots + \phi_p W_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}$$

Antes da utilização do ARIMA na previsão da a partir de séries temporais vários passos de pré-processamento são necessários.

2.3. Metodologia Box-Jenkins para séries temporais

Segundo Morettin e Tolo (2004) a metodologia de Box e Jenkins (1970) “consiste em ajustar modelos auto-regressivos integrados a médias móveis – ARIMA (p, d, q) – a um conjunto de dados”. Este conjunto de dados constitui a base para a construção do modelo mais adequado. Conforme Werner e Ribeiro (2003), estes modelos matemáticos abordam o comportamento da autocorrelação entre os valores da série temporal e, a partir disso, possibilitam realizar previsões, principalmente para curto prazo.

A construção de um modelo ARIMA baseado na metodologia Box-Jenkins obedece a um ciclo iterativo, em que as componentes do modelo inicialmente são escolhidas baseando-se nos próprios dados e, posteriormente sofrem ajustes até se obter o melhor modelo.

Conforme Morettin e Tolo (2004) este ciclo iterativo é composto por quatro etapas - identificação, estimação, verificação e previsão – descritas a seguir.

- *Etapa de identificação*: consiste em verificar qual modelo descreve o comportamento da série, valendo-se da interpretação dos correlogramas das funções de autocorrelação (FAC) e das funções de autocorrelação parciais (FACP);
- *Etapa de estimação*: realiza-se a estimativa dos parâmetros do componente auto-regressivo, do componente de médias móveis e da variância;
- *Etapa de verificação*: consiste em analisar se o modelo escolhido descreve adequadamente o comportamento da série, por meio da análise dos resíduos;
- *Etapa de previsão*: etapa que representa o objetivo principal, realizada apenas se as etapas anteriores forem satisfatórias.

Assim, sempre que o modelo não se mostrar adequado, as etapas devem ser repetidas. De outro modo, as etapas devem ser realizadas tantas vezes forem necessárias até que seja obtido um modelo satisfatório que descreva o processo gerador da série (ZHANG, 2003; MORETTIN; TOLOI, 2004).

Conforme exposto anteriormente, na etapa de identificação analisa-se o comportamento da série nos correlogramas de FAC e FACP e verifica-se a estacionariedade da mesma. Na etapa de estimação são estabelecidos os possíveis parâmetros por meio do comportamento da série nos correlogramas da FAC e FACP da série já estacionarizada utilizando os valores estatisticamente significativos. Uma série não estacionária apresenta decaimento lento para zero em seu correlograma FAC, por exemplo. Na etapa de verificação, é realizada a análise dos resíduos, sendo os resíduos a diferença entre a série em original e a série ajustada, também conhecido como erro aleatório. Estes não devem ser autocorrelacionados, devem possuir média zero e variância constante. Uma vez que os resíduos não apresentem estas características, o ciclo iterativo deve ser iniciado novamente.

Na fase de verificação, a análise do modelo consiste em verificar os menores valores para os critérios AIC e BIC (*Akaike Information Criterion* e *Bayesian Information Criterion*, respectivamente), tendo em vista que, estes critérios tem por objetivo indicar o modelo mais parcimonioso, isto é, com menor número de parâmetros, uma vez que são construídos com base na variância estimada (σ) e no tamanho da amostra (n). O modelo que apresentar o menor valor de AIC e BIC será o que melhor se ajustará aos dados (LIMA JUNIOR et al, 2013).

Após o ajuste do modelo mais adequado a série, avalia-se as previsões obtidas quanto a sua acuracidade por meio do valor do *Mean Absolute Percentage Error* (MAPE), na qual, segundo Klidzio (2009), melhores serão as previsões fornecidas pelo modelo proposto quanto menor for o valor do MAPE.

2.4. Estacionariedade – Teste KPSS e Dickey-Fuller aumentado

Os modelos de previsão auto-regressivos comumente utilizados baseiam-se nas características de linearidade da série temporal e estacionariedade. De acordo com Gujarati (2000), uma série temporal é estacionária se “suas médias e variância forem constantes ao longo do tempo e o valor da covariância entre dois períodos depender da defasagem entre dois períodos e não do período de tempo efetivo”. Do contrário, a série é definida como sendo uma série temporal não-estacionária.

A estacionariedade de uma série temporal deve ser comprovada através de testes. Na literatura podem ser encontrados diversos métodos para teste de estacionariedade de séries temporais, sendo que o resultado da análise é fundamental para a adequada realização das

demais etapas do estudo, tendo em vista o método adotado (ARIMA). Assim, no presente estudo utilizou-se o teste da raiz unitária desenvolvido por Kwiatkowski et al. (1992).

3. Metodologia

No presente estudo, utilizou-se o método ARIMA para analisar a variação homóloga do Índice de Preços ao Consumidor Nacional (IPCN), indicador calculado trimestralmente pelo Instituto Nacional de Estatística de Angola.

A pesquisa combina abordagens qualitativas e quantitativas e, quanto aos objetivos, caracteriza-se como exploratório-descritiva (LAKATOS; MARCONI, 2007). O modelo ARIMA foi selecionado para estimar a inflação devido à sua flexibilidade na análise de séries temporais, permitindo a utilização de dados históricos para projetar tendências futuras do comportamento inflacionário.

Para o tratamento e análise dos dados, recorreu-se ao software estatístico Gretl. A seleção do melhor modelo baseou-se nos critérios de Akaike (AIC – Critério de Informação de Akaike) e Bayesiano (BIC – Critério de Informação Bayesiano), considerando que a combinação com os menores valores de AIC e BIC representa o modelo mais adequado para a série de dados (LIMA JÚNIOR, 2013)

4. Aplicação do Modelo ARIMA

Definido o produto cuja série temporal seria analisada e de posse dos dados históricos, procedeu-se a aplicação do método ARIMA seguindo as etapas propostas por Box e Jenkins (1970).

4.1. Identificação

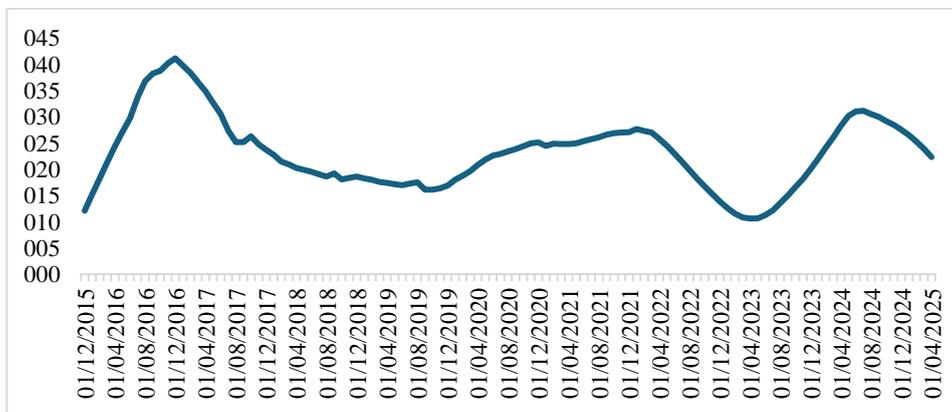
Com os dados em posse, realizou-se a análise descritiva sobre a inflação homóloga da série com o propósito de compreender as informações e analisar suas características. As medidas descritivas utilizadas foram médias, desvio padrão, limite inferior e superior e coeficiente de variação. Na Tabela 1, nota-se uma ligeira variabilidade da inflação alguns meses, a média mensal da variação homóloga do IPCN representativa, visto que o coeficiente de variação foi inferior a 30%. A amplitude entre os limites (30,5 unidades) reforça a necessidade de investigar a distribuição dos dados para melhor compreensão da sua variabilidade.

Tabela 2 – Estatística descritivas do IPCN (Dez/15 a abril/25)

Média	Desvio padrão	Limite Inferior	Limite Superior	Coefficiente de variação
23,2	6,9	10,6	41,1	29,8%

Fonte: Elaborado pelo autor

Na identificação dos modelos adequados, deve-se examinar o comportamento no gráfico da evolução temporal da série e verificar a estacionariedade. Numa primeira observação, o gráfico não apresenta uma tendência. Mas para a comprovação de estacionariedade recorreu-se aos testes Dicky-Fuller aumentado, KPSS e os correlogramas da FAC e FACP.



Fonte: INE (Elaborado pelo autor)

4.1.1. Teste Aumentado de Dickey-Fuller (ADF) para o IPCN

Os resultados do teste ADF rejeitam fortemente a hipótese nula de raiz unitária (p-valores significativos de 6,589e-05 e 0,0003285), indicando que a série do IPCN é estacionária. Conclui-se que a série pode ser analisada diretamente sem diferenciação adicional, sendo adequada para modelos ARIMA.

```

Teste Aumentado de Dickey-Fuller para IPCN
testar para baixo a partir de 12 defasagens, critério AIC
tamanho da amostra: 109
hipótese nula de raiz unitária: a = 1

teste com constante
incluindo 3 defasagens de (1-L)IPCN
modelo: (1-L)y = b0 + (a-1)*y(-1) + ... + e
valor estimado de (a - 1): -0,0453958
estatística de teste: tau_c(1) = -4,74502
p-valor assintótico 6,589e-05
coeficiente de 1ª ordem para e: -0,040
diferenças defasadas: F(3, 104) = 124,814 [0,0000]

com constante e tendência
incluindo 3 defasagens de (1-L)IPCN
modelo: (1-L)y = b0 + b1*t + (a-1)*y(-1) + ... + e
valor estimado de (a - 1): -0,0486157
estatística de teste: tau_ct(1) = -4,86414
p-valor assintótico 0,0003285
coeficiente de 1ª ordem para e: -0,043
diferenças defasadas: F(3, 103) = 124,716 [0,0000]
    
```

Figura 1 – Teste de estacionariedade Dicky-Fuller aumentado

4.1.2. Análise do Teste KPSS para o IPCN

O teste KPSS, que avalia a hipótese nula de estacionariedade, apresentou uma estatística de teste de 0,27277, abaixo dos valores críticos a 10% (0,349), 5% (0,462) e 1% (0,735). Isso indica que não há evidências para rejeitar a hipótese nula, ou seja, a série do IPCN é estacionária (valor $p > 0,10$). Esse resultado corrobora as conclusões do teste ADF, reforçando a adequação da série para modelagem sem diferenciação.

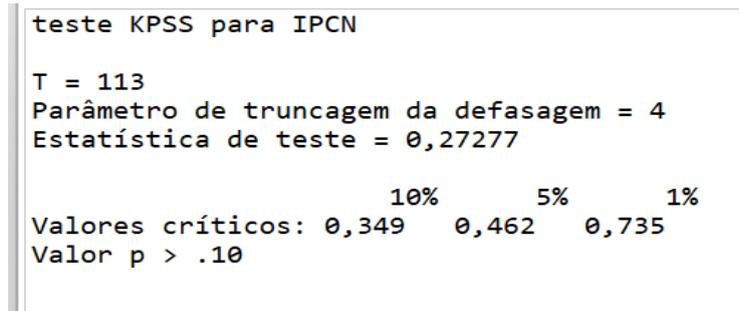
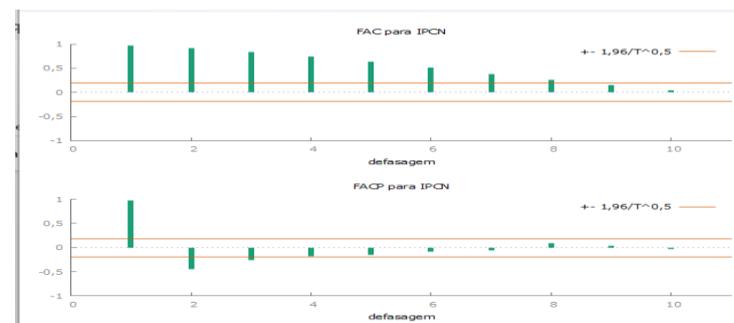


Figura 2 – Teste de estacionariedade KPSS

De acordo com Kwiatkowski (1992), o teste KPSS complementa o ADF, pois testa a estacionariedade diretamente, enquanto o ADF testa a presença de raiz unitária. Ambos convergem para a mesma conclusão.

4.1.3. Correlograma da FAC e FACP do IPCN



Função de autocorrelação para IPCN
 ***, **, * indicam significância aos níveis de 1%, 5% e 10%
 usando erro padrão $1/T^{0,5}$

Defas.	FAC		FACP		Estat. Q	[p-valor]
1	0,9691	***	0,9691	***	108,9681	[0,000]
2	0,9122	***	-0,4427	***	206,3908	[0,000]
3	0,8339	***	-0,2555	***	288,5387	[0,000]
4	0,7379	***	-0,1759	*	353,4583	[0,000]
5	0,6274	***	-0,1480		400,8151	[0,000]
6	0,5071	***	-0,0856		432,0444	[0,000]
7	0,3818	***	-0,0509		449,9164	[0,000]
8	0,2610	***	0,0885		458,3461	[0,000]
9	0,1479		0,0401		461,0802	[0,000]
10	0,0434		-0,0289		461,3176	[0,000]

Figura 3 – Correlograma da FAC e FACP do IPCN

Observa-se na Figura 3 o correlograma da FAC e FACP da série, a função de autocorrelação e a função autocorrelação parcial apresentaram-se significativos.

4.2. Estimação

Com base nos testes efetuados (KPSS, ADF e análise do correlograma), a série IPCN revelou-se estacionária, não havendo necessidade de diferenciação. Assim, a modelagem pode seguir diretamente com a classe de modelos ARMA (p, q), uma vez que a condição de estacionariedade — pré-requisito para este tipo de especificação — está satisfeita.

O próximo passo será a identificação da ordem (p, q), que poderá ser feita com base nas formas do correlograma (FAC e FACP).

Os modelos verificados, foram encontrados quatro modelos concorrentes os quais são significativos (apresentam coeficientes com *p-value* inferior a 0,05) e possuem resíduos brancos, apresentados na Tabela 2.

Tabela 2 – Principais modelos ajustados para o IPCN

Modelo	Pârametro	P-valor	AIC	BIC
ARMA (2,1)	$\phi_1 = 1,9395$	0,0000	224,9374	238,5743
	$\phi_2 = -0,9691$	0,0000		
	$\theta_1 = -0,4028$	0,0003		
ARMA (1,1)	$\phi_1 = 0,9759$	0,0000	320,1681	331,0776
	$\theta_1 = 0,6996$	0,0000		
ARMA (2,2)	$\phi_1 = 1,948$	0,0000	223,7645	240,1288
	$\phi_2 = -0,9770$	0,0000		
	$\theta_1 = -0,3219$	0,0010		
	$\theta_1 = -0,1654$	0,0690		

Fonte: Elaborado pelo autor

4.3. Verificação

Após a escolha do melhor ajuste, o passo seguinte foi a verificação dos correlogramas FAC e FACP dos resíduos.

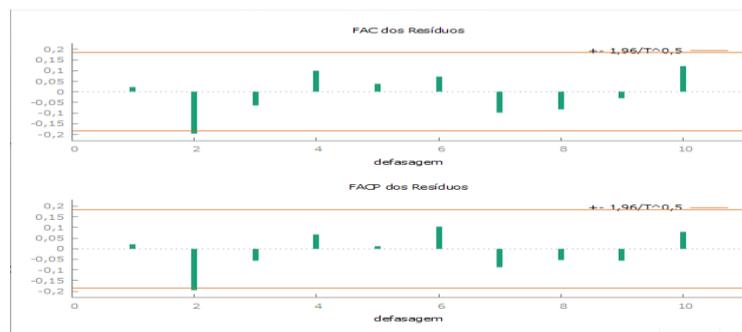


Figura 4 – Correlograma residual do modelo ARMA (2, 1)

De acordo com Figura 4 foi possível identificar que os resíduos se apresentaram não-correlacionados, uma vez que, se encontram dentro dos limites de confiabilidade. o que sugere que

o modelo ARMA escolhido é adequado, o seja, o modelo pode ser mantido. Os resíduos possuem média zero e variância constante.

4.4. Previsão

Visto que a análise dos resíduos permitiu a validação do modelo, realizou-se a previsão para o período de análise, conforme o gráfico 4, de forma a verificar o comportamento futuro do IPCN.

Gráfico 2 – Resíduos do Modelo ARMA (2,1)



Os resíduos oscilam em torno de zero ao longo do tempo, o que é desejável. Isso indica que o conseguiu capturar bem a estrutura da série. Não há tendência de crescimento ou decrescimento dos resíduos, o que é um sinal de resíduos estacionários e sem autocorrelação visível a olho nu.

Gráfico 3 – IPCN efetivo vs ajustado

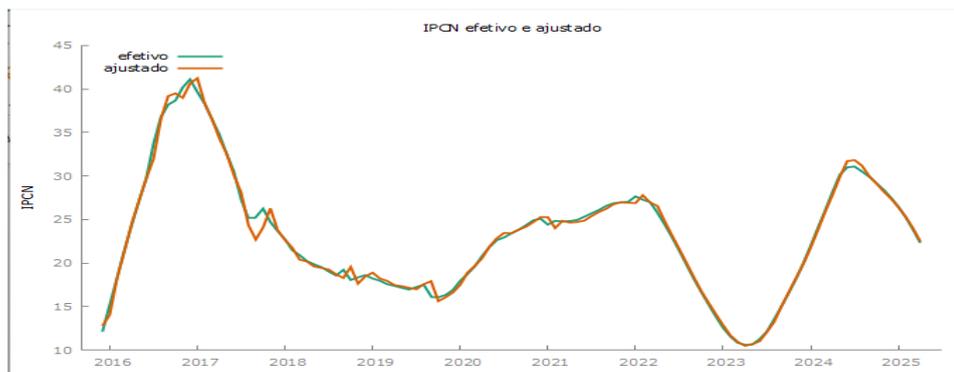
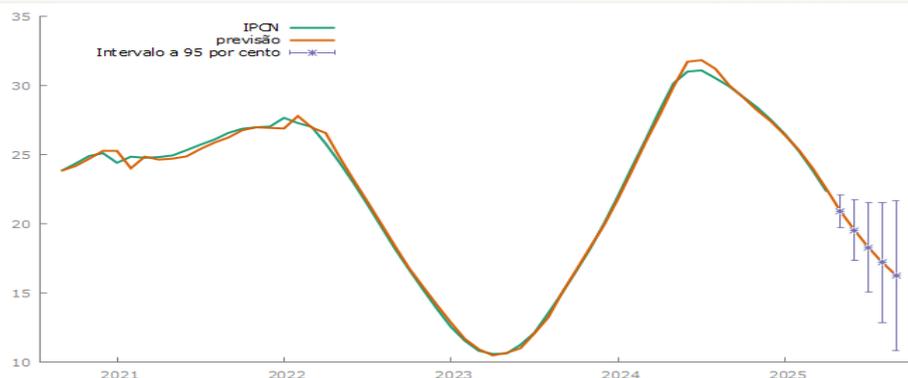


Gráfico 4 – Previsão do modelo ARMA(2,1)



A linha da previsão (laranja) acompanha muito bem a linha do IPCN observado (verde) ao longo do tempo, indicando que o modelo utilizado teve bom desempenho de ajuste na amostra.

Tabela 3 – Previsão do modelo ARMA (2,1)

Período	Valores reais	Valores previstos	Limite inferior	Limite superior
Fev/25	25,26	25,33		
Mar/25	23,85	24,01		
Abr/25	22,32	22,49		
Mai/25	-	20,89	19,70	22,08
Jun/25	-	19,54	17,36	21,72
Jul/25	-	18,29	15,06	21,53
Ago/25	-	17,19	12,87	21,52
Set/25	-	16,27	10,86	21,67

Fonte: Elaborado pelo autor

Observa-se na Figura 10 que o modelo ajustado converge para a série original, com seus resíduos próximos a zero, indicando que o modelo ajustado representa IPCN. A Tabela 4 apresenta o período, os valores reais e os valores previstos pelo modelo com os limites de confiabilidade, a previsão do modelo para maio, junho, julho, agosto e setembro de 2025.

4.5. Resumo da Qualidade do Ajustamento do Modelo ARMA

- MAE (Erro Absoluto Médio) = 0,3872

Em média, as previsões diferem dos valores reais em cerca de 0,39 unidades, o que é um bom resultado, especialmente considerando dados de inflação.

- MAPE (Erro Percentual Médio Absoluto) = 1,71%

Muito baixo. O modelo erra apenas 1,71% em média, o que representa elevada precisão preditiva.

- U2 de Theil (0,405)

Como está abaixo de 1, confirma que o modelo ARMA tem desempenho superior a uma previsão ingênua (por exemplo, usar o valor do período anterior como previsão). Quanto mais próximo de 0, melhor.

Conclusão

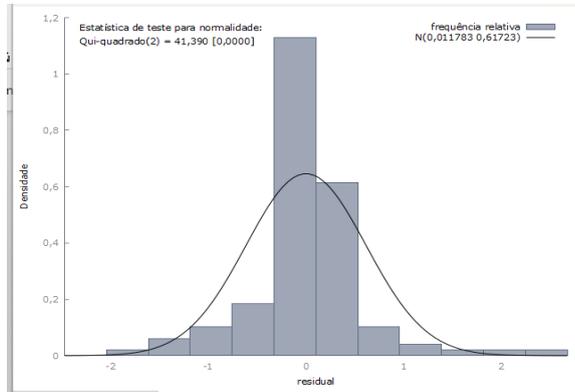
Com base na análise efetuada, conclui-se que a série temporal do Índice de Preços no Consumidor Nacional (IPCN) apresenta características de estacionaridade, confirmadas pelos testes de Dickey-Fuller Aumentado e KPSS, que indicaram a não necessidade de diferenciação. O correlograma dos resíduos também reforça a hipótese de ausência de autocorrelação significativa, validando a adequação do modelo ARMA (p,q) como estrutura apropriada para a modelação do comportamento da inflação mensal em Angola. A seleção do modelo obedeceu critérios estatísticos e de significância, e os resíduos do modelo ajustado revelaram comportamento aleatório, sugerindo que os pressupostos do modelo foram satisfeitos.

A avaliação da previsão do modelo revelou resultados satisfatórios, com um Erro Percentual Médio Absoluto (MAPE) de apenas 1,71%, indicando elevada precisão nas previsões. O valor da estatística U^2 de Theil (0,405) demonstra que o modelo supera as previsões ingênuas, como o uso do último valor observado. As previsões para o período de fevereiro a setembro de 2025 indicam uma tendência de desaceleração no nível geral de preços, sugerindo um abrandamento da inflação, o que pode ser útil para a formulação de políticas económicas e tomada de decisão por parte dos agentes económicos.

Referências

- Gujarati, D. N. (2000). *Econometria básica*. São Paulo: Pearson Makron Books.
- Instituto Nacional de Estatística – INE. (2025, maio). *Índice de Preços ao Consumidor Nacional*.
- Kirchner, R., Souza, A. M., & Stumm, E. M. F. (2011). A modelagem como ferramenta de gestão. *Latin American Journal of Business Management*, 2(1), 2–23.
- Klidzio, R. (2009). *Modelos de previsão aplicados ao controle de qualidade com dados autocorrelacionados* (Dissertação de Mestrado). Universidade Federal de Santa Maria – UFSM, Santa Maria, RS.
- Krajewski, L. J., Ritzman, L., & Malhotra, M. (2009). *Administração de produção e operações* (8ª ed., Trad. M. S. Ribeiro). São Paulo: Pearson Prentice Hall.
- Lakatos, E. M., & Marconi, M. A. (2007). *Metodologia do trabalho científico* (17ª ed.). São Paulo: Atlas.
- Laugeni, F. P., & Martins, P. G. (2015). *Administração da produção* (3ª ed.). São Paulo: Saraiva.
- Ministério das Finanças – MINFIN. (2023). *Relatório anual de preços*.
- Morettin, P. A., & Tolo, C. M. C. (2004). *Análise de séries temporais*. São Paulo: Edgard Blücher.

Anexos



Distribuição de frequência para residual, observações 1-113
 número de classes = 11, média = 0,011783, desvio padrão = 0,617233

intervalo	pt. médio	frequência	rel.	acum.
< -1,6103	-1,8258	1	0,88%	0,88%
-1,6103 - -1,1793	-1,3948	3	2,65%	3,54%
-1,1793 - -0,74825	-0,96376	5	4,42%	7,96% *
-0,74825 - -0,31724	-0,53275	9	7,96%	15,93% **
-0,31724 - 0,11376	-0,10174	55	48,67%	64,60% *****
0,11376 - 0,54477	0,32927	30	26,55%	91,15% *****
0,54477 - 0,97578	0,76028	5	4,42%	95,58% *
0,97578 - 1,4068	1,1913	2	1,77%	97,35%
1,4068 - 1,8378	1,6223	1	0,88%	98,23%
1,8378 - 2,2688	2,0533	1	0,88%	99,12%
>= 2,2688	2,4843	1	0,88%	100,00%

Teste para a hipótese nula de distribuição normal:
 Qui-quadrado(2) = 41,390 com p-valor 0,00000

Teste ARCH de ordem 12

	coeficiente	erro padrão	razão-t	p-valor
alpha(0)	0,0977354	0,109350	0,8938	0,3739
alpha(1)	0,517276	0,105054	4,924	3,94e-06 ***
alpha(2)	-0,0552309	0,117979	-0,4681	0,6408
alpha(3)	-0,0860264	0,117913	-0,7296	0,4676
alpha(4)	0,0164424	0,115851	0,1419	0,8875
alpha(5)	-0,0624781	0,106038	-0,5892	0,5572
alpha(6)	0,116596	0,102918	1,133	0,2603
alpha(7)	-0,182399	0,102207	-1,785	0,0778 *
alpha(8)	0,201093	0,103437	1,944	0,0551 *
alpha(9)	-0,0637748	0,105314	-0,6056	0,5464
alpha(10)	-0,000693793	0,105096	-0,006602	0,9947
alpha(11)	0,115106	0,105078	1,095	0,2763
alpha(12)	0,129466	0,0968602	1,337	0,1848

Hipótese nula: efeito ARCH não está presente
 Estatística de teste: LM = 34,9713
 com p-valor = P(Qui-quadrado(12) > 34,9713) = 0,000473258

Teste para autocorrelação até a ordem 12

Ljung-Box Q' = 37,0551,
 com p-valor = P(Qui-quadrado(9) > 37,0551) = 2,573e-005