



Nota Técnica SEI nº 49638/2022/ME

Assunto: **definição do Fator de Produtividade (Fator X) referente ao reajuste de preços de medicamentos para o ano de 2023.**

1. INTRODUÇÃO

1. Esta Nota Técnica tem por objetivo apresentar o cálculo do fator de produtividade (Fator X), conforme metodologia exposta pela Câmara de Regulação do Mercado de Medicamentos (CMED) nas Resoluções CMED nº 1, de 23 de fevereiro de 2015, e nº 05 de 12 de novembro de 2015, que estabelecem os critérios de composição de fatores para o ajuste de preços de medicamentos^[1].

2. A Lei nº 10.742, de 06 de outubro de 2003, prevê o reajuste anual dos preços de medicamentos baseado no modelo de regulação por teto de preços (*price cap*). O modelo prevê a aplicação de um índice geral de preços^[2], um fator de produtividade (X) e dois fatores de ajuste de preços, um entre (Y) e o outro intra-setores (Z), conforme descrito abaixo:

$$VPP = IPCA - X + Y + Z, \text{ onde}$$

- VPP = variação percentual do preço do medicamento;
- IPCA = taxa de inflação medida pela variação percentual do Índice de Preços ao Consumidor Amplo;
- X = fator de produtividade;
- Y = fator de ajuste de preços relativos entre setores;
- Z = fator de ajuste de preços relativos intra-setores.

3. Define-se Fator X como o indicador que mensura a produtividade da indústria farmacêutica brasileira. A partir dos valores observados, estima-se a sensibilidade (elasticidade) da produtividade à taxa de juros de mercado, à taxa de câmbio, à inflação e ao Produto Interno Bruto (PIB), variáveis que retratam a situação macroeconômica do País. Conhecidas tais sensibilidades, diante de valores previstos das variáveis exógenas, torna-se possível prever valores para a produtividade. Tem-se, então, uma projeção esperada da produtividade média da indústria farmacêutica para o próximo ano.

4. O cálculo do fator de produtividade (Fator X) permite repassar aos preços projeções de ganhos de produtividade das empresas produtoras de medicamentos. Este dispositivo cria incentivos para que as empresas busquem alcançar ganhos contínuos de eficiência, visto que toda a diferença entre o preço de mercado máximo (preço-fábrica, no caso dos medicamentos) e os custos de produção do bem pode ser por elas apropriada. Isto significa que um ganho de produtividade superior ao valor projetado pelo regulador poderia ser inteiramente retido pela empresa produtora do medicamento.

5. A fórmula para o cálculo do Fator X, tal como expressa na Resolução CMED nº 05/2015, é apresentada abaixo:

$$\text{Equação 1: } X = 100 * \max_{\text{t}} \left[\left[\frac{\mu(X_t(h))}{\mu(X(t+h))} \right] - 1 \right], \text{ onde}$$

- X é o fator da produtividade projetada em percentuais
- $\mu(X_t(h))$ é a média da série prevista do índice de produtividade trabalho do setor farmacêutico de origem t e horizonte h
- $\mu(X(t+h))$ é a média do índice de produtividade trabalho do setor farmacêutico de origem t e horizonte h

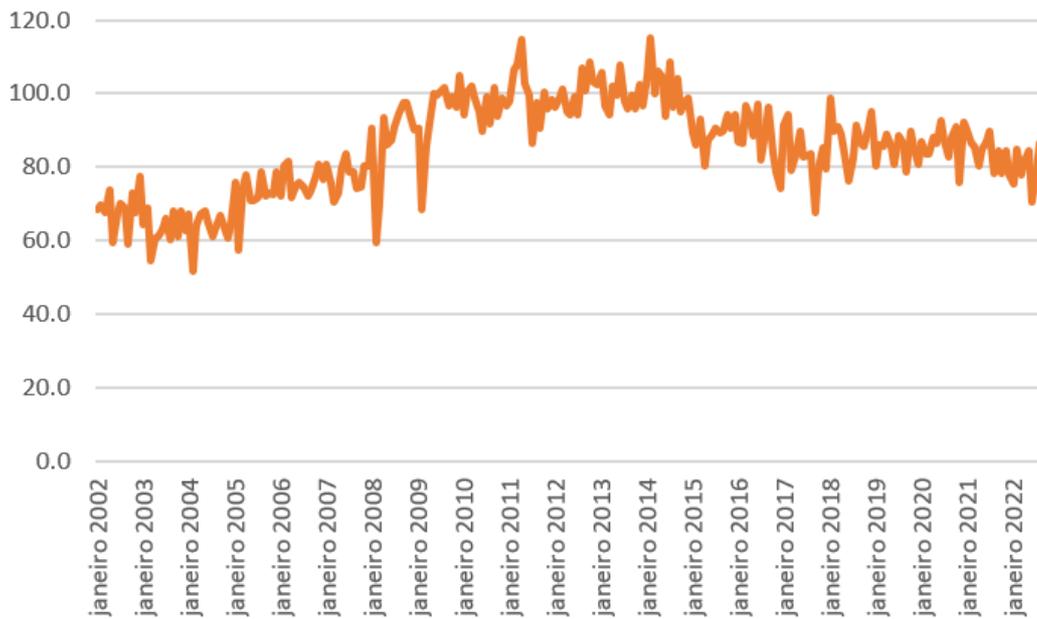
6. O índice que mensura a produtividade do trabalho no setor farmacêutico consiste na média das predições econométricas da produtividade para os próximos 12 meses. O indicador é a razão entre o Índice de Produção Física da Indústria Farmacêutica de determinado mês e o Total de Horas Trabalhadas na Indústria Farmacêutica no respectivo mês, para o período a partir de janeiro de 2002.

Equação 2: $X(t+h) = \frac{IPF_{t+h}}{ITHT_{t+h}}$, onde

- IPF_{t+h} é o Índice de Produção Física do setor farmacêutico de origem t e horizonte h total
- $ITHT_{t+h}$ é o Índice do Total de Horas Trabalhadas de setor farmacêutico de origen t e horizonte h

7. A Figura 1 apresenta a série temporal do Índice de Produção Física do Setor Farmacêutico, extraída da Pesquisa Industrial Mensal de Produção Física (PIM-PF) do Instituto Brasileiro de Geografia e Estatística (IBGE), que inclui a fabricação de produtos farmoquímicos e farmacêuticos. Esse índice é o numerador utilizado no cálculo do índice de produtividade do trabalho do setor farmacêutico.

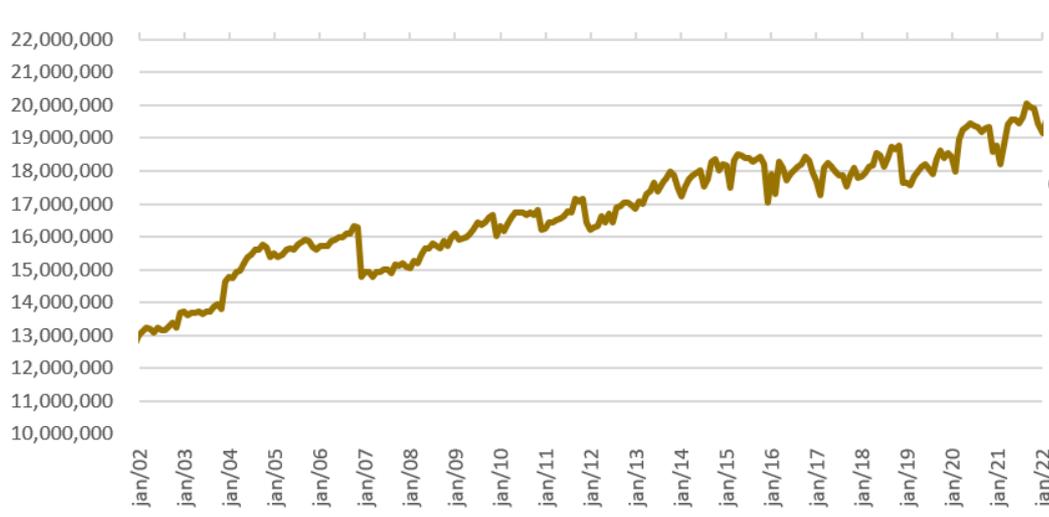
Figura 1: Número Índice de Produção Física Industrial – Fabricação de Produtos Farmoquímicos e Farmacêuticos, com ajuste sazonal



Fonte: IBGE / SIDRA.

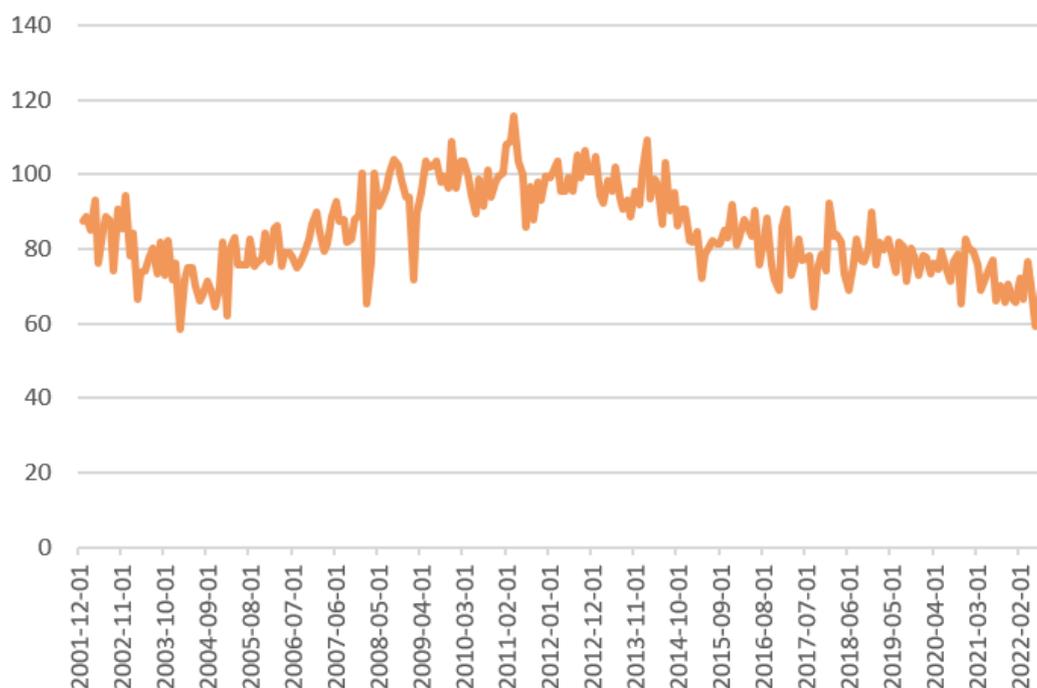
8. O denominador do Índice de Produtividade do Trabalho do Setor Farmacêutico é o Total de Horas Trabalhadas na Indústria Farmacêutica. A série foi construída utilizando informações do Relatório Anual de Informações Sociais (RAIS) e do Cadastro Geral de Empregados e Desempregados (CAGED). Os filtros utilizados e a metodologia de construção da série estão detalhados no Apêndice II deste relatório. A série temporal pode ser observada na Figura 2.

Figura 2: Horas trabalhadas no setor farmacêutico



9. O Índice de Produtividade do Trabalho do Setor Farmacêutico foi construído com dados disponíveis a partir de janeiro de 2002, gerando uma série temporal com 248 conforme Figura 3 abaixo.

Figura 3: Índice de Produtividade do Trabalho do Setor Farmacêutico



10. Conforme as Resoluções CMED nº 01/2015 e nº 05/2015, a modelagem e previsão do índice de produtividade devem ser estimadas utilizando técnicas de análise econométrica de séries temporais, conforme a abordagem de Mínimos Quadrados Ordinários (MQO) proposta por Box, Jenkins e Reinsel, que orienta (i) analisar e verificar a estacionariedade das séries temporais e/ou torná-las estacionárias; (ii) identificar o modelo de ordem da autocorrelação e autocorrelação parcial através do critério de Akaike e Schwarz; (iii) testar o impacto de variáveis exógenas – taxa de câmbio real, taxa de crescimento real do produto interno bruto da economia brasileira, taxa de juros real e taxa de variação do IPCA – sobre o Índice de Produtividade do Trabalho do Setor Farmacêutico através dos testes T e de Wald; e (iv) estimar o modelo e verificar o modelo identificado para obter a série de previsão de erro quadrático mínimo.

11. O Apêndice I descreve as séries temporais utilizadas na estimação, bem como suas fontes. Os testes estatísticos realizados, bem como os passos de seleção do modelo do cálculo do Fator X estão descritos no Apêndice III.

12. O Fator X estimado através do modelo econométrico pode apresentar valores negativos, representando queda na produtividade do trabalho da indústria farmacêutica, ou valores positivos, representando crescimento na produtividade do trabalho da indústria farmacêutica. Entretanto, conforme concepção teórica do esquema regulatório mundialmente adotado, o Fator X deve gerar incentivos às empresas e ao setor a buscarem ganhos de produtividade de forma organizada. O Fator X, portanto, não deve assumir valores negativos, pois nesse caso os incentivos seriam perversos: as empresas menos produtivas seriam beneficiadas com aumentos de preços. Assim, conforme disposto na Resolução CMED nº 05/2015, quando o modelo econométrico gerar previsões de queda no Índice de Produtividade do Trabalho do Setor Farmacêutico, o Fator X deve ser igual à zero.

2. CÁLCULO DO FATOR DE PRODUTIVIDADE (FATOR X) DA INDÚSTRIA FARMACÊUTICA NO BRASIL

2.1 Base de Dados

13. De acordo com o disposto nas Resoluções CMED nº 01/2015 e nº 05/2015 foram construídas as seguintes séries temporais:

i. Variável endógena: índice de produtividade do trabalho da indústria farmacêutica brasileira obtida pela divisão, em cada período, do índice de quantum dessazonalizado da produção física da indústria farmacêutica, divulgado na Pesquisa Industrial Mensal de Produção Física (PIM-PF), pelo total de horas mensais do pessoal ocupado na indústria farmacêutica, calculado a partir de informações do RAIS e do CAGED;

ii. Variáveis exógenas:

ii.1 variação real da taxa de câmbio livre do Real em relação ao Dólar dos Estados Unidos da América (EUA), ajustada pelo Índice de Preços ao Consumidor Ampliado (IPCA) e pelo Consumer Price Index (CPI) do Bureau of Labor Statistics (BLS) dos EUA;

ii.2 taxa de juros real ex post, obtida pela taxa média ajustada dos financiamentos diários apurados no Sistema Especial de Liquidação e de Custódia para títulos públicos federais (taxa Selic), ajustada pelo IPCA;

ii.3 variação real do Produto Interno Bruto (PIB), obtida através do PIB nominal, e ajustada pelo

IPCA;

ii.4 variação mensal do IPCA.

2.2 Metodologia

14. Conforme disposto, o modelo estimado segue a especificação proposta por Box e Jenkins, que consiste em ajustar um modelo autorregressivo integrado de médias móveis - ARIMA(p, d, q) com o uso de variáveis exógenas.

15. O modelo foi estimado utilizando o *software* estatístico R e R studio. Ao estimar o modelo, o *software* testa todas as possíveis combinações factíveis de vetores autorregressivos e médias móveis e sugere a melhor ordem do modelo, considerando critérios de robustez como os de Akaike (AIC) Schwarz (BIC).

2.3 Cálculo do Fator X

16. Após a seleção do modelo adequado para se projetar a série do Índice de Produtividade do Trabalho da Indústria Farmacêutica até junho de 2023, de acordo o disposto no parágrafo 3º do artigo 2º da Resolução CMED nº 05/2015, é preciso estabelecer o valor do Fator X para o ano seguinte. O Fator X é calculado através da variação percentual entre a média dos 12 meses do Índice da Produtividade do Trabalho do Setor Farmacêutico Projetado e a média dos 12 meses do Índice observado.

3. CONCLUSÃO

17. O cálculo do Fator X, de acordo com a metodologia disposta nas Resoluções CMED nº 01/2015 e nº 05/2015, com os procedimentos descritos na presente Nota Técnica e com os dados disponíveis para as séries observadas bem como suas previsões, indica uma **variação estimada de 0% na produtividade da indústria para o período entre julho de 2022 e junho de 2023.**

À consideração superior.

Documento assinado eletronicamente

MARIANA PICCOLI L. CAVALCANTI

Coordenadora-Geral de Inovação, Indústria de Rede e Saúde

De acordo.

Documento assinado eletronicamente

ANDREY VILAS BOAS DE FREITAS

Subsecretário de Advocacia da Concorrência

De acordo.

Documento assinado eletronicamente

ALEXANDRE MESSA

Secretário de Acompanhamento Econômico

APÊNDICE I - FONTES DE DADOS UTILIZADAS

Data de Coleta dos Dados: 1º/11/2022

- i. Produto Interno Bruto (PIB) - Valores correntes (R\$ milhões) - mensal. Fonte: Banco Central do Brasil. Série 4380 do SGS/BCB.
- ii. Taxa de câmbio - R\$/US\$ - Livre (compra) - média de período - R\$ média mensal. Fonte: Banco Central do Brasil. Série 3697 do SGS/BCB.
- iii. Taxa de juros - Selic acumulada no mês anualizada base 252 - % a.a. Fonte: Banco Central do Brasil. Série 4189 do SGS/BCB.
- iv. Consumer Price Index (CPI) - Número Índice - mensal. Fonte: Bureau of Labor Statistics dos EUA. Série CUSR0000SA0.
- v. Índice Nacional de Preços ao Consumidor Amplo (IPCA) - número índice (base fixa dez/1993=100). Fonte: IBGE.

Tabela 1737 do SIDRA/IBGE.

- vi. Produção Física Industrial (PIM/PF) - indústria farmacêutica - Número-índice com ajuste sazonal (2012=100) (Número-índice). Fonte: IBGE. Tabela 8159 do SIDRA/IBGE. Selecionar para seções e atividades industriais apenas a opção 3.21 - Fabricação de produtos farmacêuticos e farmoquímicos.
- vii. Pessoal ocupado em 31/12, vínculos CLT. Considerar as classes 21.21-1, 21.22-0 e 21.23-8 da CNAE 2.0 (a partir de 2006) e as classes 24.52-0, 24.53-8, 24.54-6 da CNAE 1.0 (até 2005) - anual. Fonte: RAIS/MTE.
- viii. Horas contratadas (média do pessoal ocupado em 31/12), vínculos CLT. Considerar as classes 21.21-1, 21.22-0 e 21.23-8 da CNAE 2.0 (a partir de 2006) e as classes 24.52-0, 24.53-8, 24.54-6 da CNAE 1.0 (até 2005) - anual. Fonte: RAIS/MTE.
- ix. Total de horas contratuais dos admitidos. Considerar as classes 24.52-0, 24.53-8, 24.54-6 da CNAE 1.0 (até dezembro/2006) e as classes 21.21-1, 21.22-0 e 21.23-8 da CNAE 2.0 (a partir de janeiro/2007) - mensal. Fonte: CAGED/MTE.
- x. Total de horas contratuais dos demitidos. Considerar as classes 24.52-0, 24.53-8, 24.54-6 da CNAE 1.0 (até dezembro/2006) e as classes 21.21-1, 21.22-0 e 21.23-8 da CNAE 2.0 (a partir de janeiro/2007) - mensal. Fonte: CAGED/MTE.
- xi. Total de empregados admitidos. Considerar as classes 24.52-0, 24.53-8, 24.54-6 da CNAE 1.0 (até dezembro/2006) e as classes 21.21-1, 21.22-0 e 21.23-8 da CNAE 2.0 (a partir de janeiro/07) - mensal. Fonte: CAGED/MTE.
- xii. Total de empregados demitidos. Considerar as classes as classes 24.52-0, 24.53-8, 24.54-6 da CNAE 1.0 (até dezembro/2006) e as classes 21.21-1, 21.22-0 e 21.23-8 da CNAE 2.0 (a partir de janeiro/2007) - mensal. Fonte: CAGED/MTE.
- xiii. Número de dias úteis - mensal. Fonte: IPEA. Série SGS12_NDIASUTEISPAS12 do IPEADATA.

APÊNDICE II - TRATAMENTO DAS BASES DE DADOS

Construção da Variável Endógena

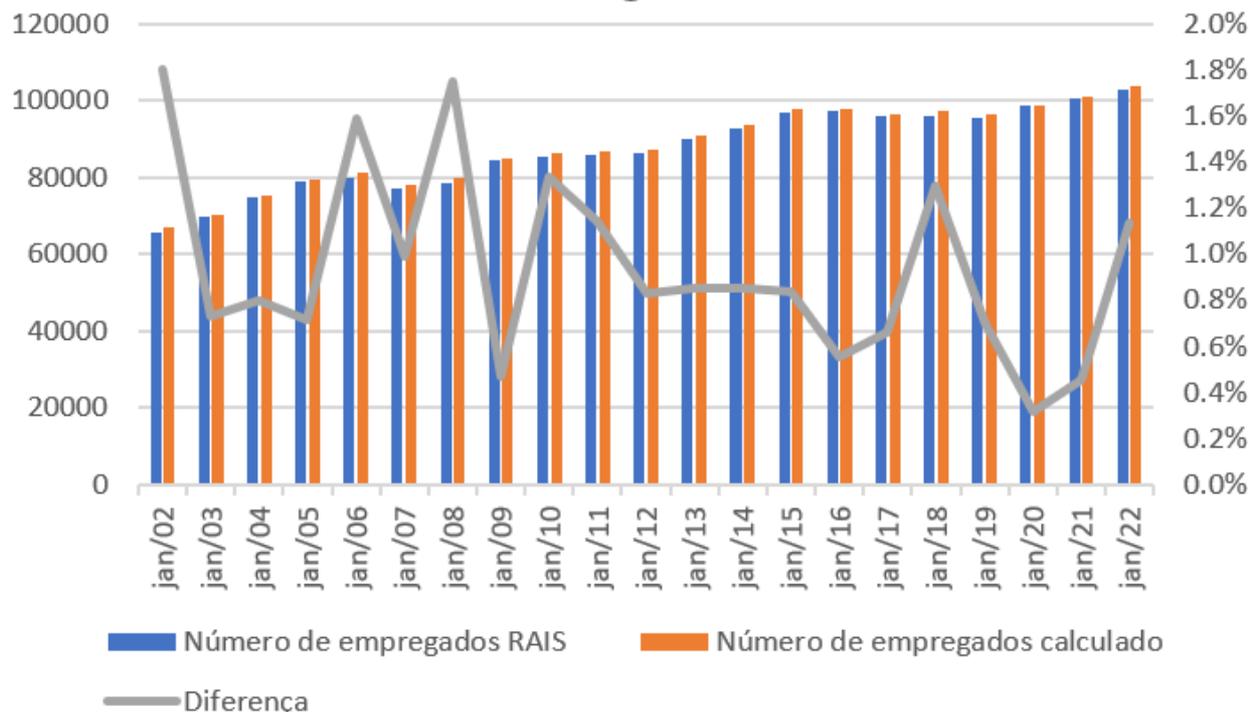
O índice de produtividade do trabalho considera o volume produzido na indústria farmacêutica, através do índice de produção física extraído da PIM/PF, em relação ao número de horas trabalhadas na indústria farmacêutica, obtida com as informações disponibilizadas nas bases de dados da RAIS e do CAGED. Portanto, as classificações de atividade econômica (CNAE) utilizadas para filtrar os dados de horas trabalhadas da RAIS e do CAGED foram as mesmas CNAEs consideradas no indicador de produção física da PIM/PF.

A RAIS fornece informações do número de empregados em todas as empresas formalizadas no Brasil e o número de horas contratadas em dezembro de cada ano. Para se obter o número de horas trabalhadas mensalmente, utilizou-se a informação do número de demitidos e de admitidos a cada mês, ou seja, o saldo mensal de postos de trabalho do CAGED e calculou-se, a partir do pessoal ocupado da RAIS em dezembro, a movimentação dos postos no ano seguinte. Assume-se que o ano y se inicia com o número de empregados em dezembro do ano $y-1$. Soma-se ao estoque de trabalhadores observado na RAIS em dezembro do ano $y-1$, o saldo registrado no CAGED em janeiro do ano t e assim por diante, entre janeiro e novembro. Em dezembro de cada ano t , se utilizou a informações anual da RAIS.

O número de horas trabalhadas mensalmente foi obtido multiplicando o número de trabalhadores no mês pela média das horas contratadas dos admitidos no mês m , contido no CAGED.

A Figura 4 apresenta os valores calculados e observados em janeiro de cada ano, assumindo que cada ano se inicia com o estoque de dezembro observado na RAIS. O hiato representa a diferença entre as duas séries em percentual.

Figura 4: Comparativo do número de empregados calculado com o número de empregados registrado na RAIS



Em geral, as diferenças encontradas foram inferiores a 1% do número de empregados registrado na RAIS. Apenas em 7 dos 21 anos verificados o hiato passou de 1%, sendo a maior diferença observada em janeiro de 2002, de 1,8%. Não obstante, 2006 é o ano em que ocorreu uma quebra na série, devido a mudança da tabela de classificações de atividade econômica (CNAE) da 1.0 para a 2.0.

Vale destacar que a indústria farmacêutica apresenta elevado grau de formalização, o que faz com que os dados do CAGED sejam uma boa referência para a movimentação de empregados no setor.

Construção das Variáveis Exógenas

Taxa de variação do Índice de Preços ao Consumidor Ampliado

$$IPCAVAR_t = \frac{ipca_t}{ipca_{t-1}}, \text{ onde:}$$

- $ipca_t$ se refere ao índice de preço ao consumidor amplo no mês;

Taxa de Câmbio Real

$$CAMBIOR_t = cambio_nom_t * \frac{uscpi_t / uscpi_{t_0}}{ipca_t / ipca_{t_0}}, \text{ onde:}$$

- $cambio_nom_t$ se refere ao câmbio nominal observado no mês;
- $uscpi_t$ se refere ao índice de preço ao consumidor dos Estados Unidos no mês;
- $ipca_t$ se refere ao índice de preço ao consumidor amplo no mês;
- t_0 se refere ao período inicial, dezembro de 2001.

Taxa de Juro real ex post

$$JUROSRT_t = \hat{i}_{real_t} = \left[\left(1 + \frac{i_t}{100} \right) \left(1 + \frac{\pi_t}{100} \right)^{-1} - 1 \right] * 100, \text{ onde:}$$

- i_t é a taxa Selic mensal acumulada em 12 meses no mês t ;
- π_t é a variação mensal do IPCA acumulado em 12 meses.

Produto Interno Bruto Real

$$PIBR_t = PIB_t * \frac{ipca_t}{ipca_{t_0}}, \text{ onde}$$

- PIB_t se refere ao Produto Interno Bruto (PIB) no mês t ;
- $ipca_t$ se refere ao IPCA no mês t ;
- t_0 se refere ao período inicial, dezembro de 2001.

APÊNDICE III - TESTES ESTATÍSTICOS EMPREGADOS E PASSOS DE SELEÇÃO DO MODELO DO CÁLCULO DO FATOR X

Todos os procedimentos econométricos foram realizados utilizando o Software R_studio, versão 4.2.2.

A modelagem, definida na Resolução CMED nº 05/2015, tem uma estrutura de séries temporais e será estimada via método de mínimos quadrados ordinários (MQO). Trata-se de uma abordagem tradicional e conhecida que busca explicar o comportamento de uma determinada variável, no caso a produtividade do trabalho, em relação a variações de outras variáveis. Como todo modelo, é impossível explicar e prever, com total precisão, todas as variações da produtividade. Essa parcela não explicada é chamada de resíduo. O método de MQO consiste num sistema de equações que mensuram a elasticidade de uma determinada variável em relação a outras de forma a minimizar a parcela residual, ou seja, explicando o máximo possível das variações da variável de interesse.

Estudo da estacionariedade das séries

Para que os testes e resultados sejam confiáveis, a abordagem MQO assume o pressuposto de estacionariedade das séries, ou seja, os resíduos devem ser independente e identicamente distribuídos (i.i.d.). A presença de correlação serial entre as observações de uma variável gera um comportamento não estacionário da série temporal. Para testar a estacionariedade, foram realizados os testes de raiz unitária Philips-Perron (PP) e de estacionariedade Kwiatkowski-Philips-Schmidt-Shin (KPSS).

O teste PP é um método não paramétrico para verificar correlação nos resíduos. A hipótese nula testada assume que há presença de raiz unitária, isto é, que a série é não estacionária. Por outro lado, o teste KPSS testa a hipótese nula de que a série é estacionária. Os resultados do teste rejeitam a hipótese nula de estacionariedade da série em nível e assumem a presença de tendência estacionária.

Tabela 1: Testes de Estacionariedade

Variável	Equação de teste	Teste Phillips-Perron				Teste KPSS			
		Hipótese nula: série tem raiz unitária				Hipótese nula: série é estacionária			
		Valor	Valor Crítico			Valor	Valor Crítico		
	Teste-Estatístico	1%	5%	10%	Teste-Estatístico	1%	5%	10%	
DIPFF	C	-33.0418	-3.458267	-2.873322	-2.572995	0.0454	0.739	0.463	0.347
	C, trend	-33.0125	-3.998395	-3.429244	-3.137814	0.0287	0.216	0.146	0.119
DPIBR	C	-20.8045	-3.458267	-2.873322	-2.572995	0.0767	0.739	0.463	0.347
	C, trend	-20.7969	-3.998395	-3.429244	-3.137814	0.0313	0.216	0.146	0.119
DCAMBIOR	C	-12.1522	-3.458267	-2.873322	-2.572995	0.2091	0.739	0.463	0.347
	C, trend	-12.1991	-3.998395	-3.429244	-3.137814	0.0369	0.216	0.146	0.119
DJUROSR	C	-9.2999	-3.458267	-2.873322	-2.572995	0.1341	0.739	0.463	0.347
	C, trend	-9.3523	-3.998395	-3.429244	-3.137814	0.0724	0.216	0.146	0.119
DIPCAVAR	C								
	C, trend								

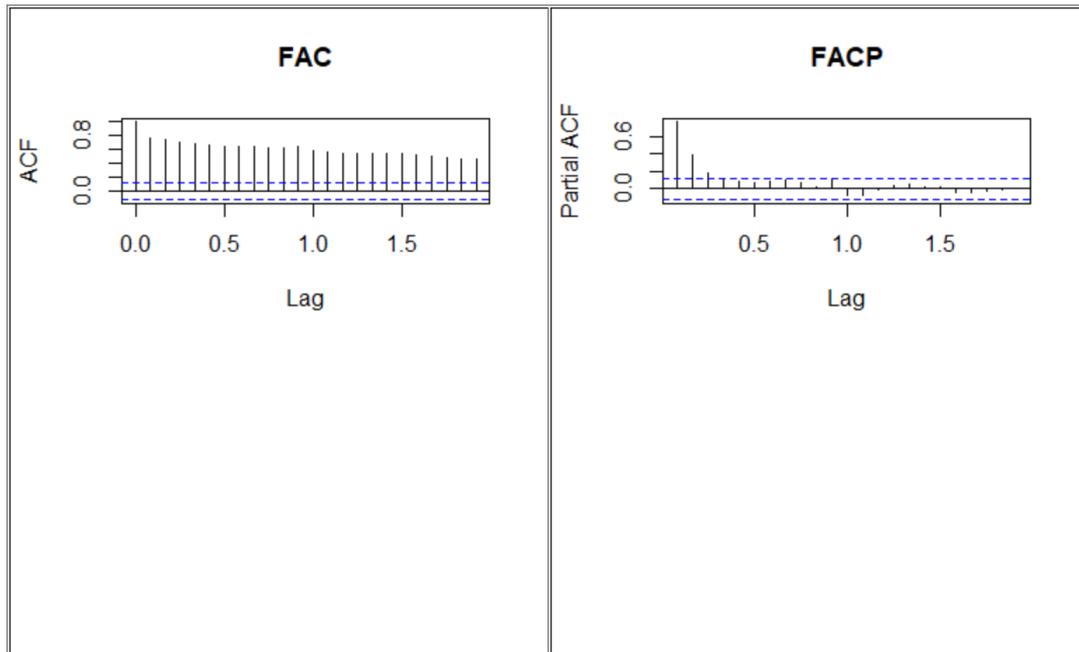
Notas: amostra de dados mensal entre janeiro de 2002 e setembro de 2022; IPFF é a série definida na equação 2 e no Apêndice II; PIBR, CAMBIOR, JUROS e IPCAVAR são as séries definidas no Apêndice II; DIPFF é a primeira diferença do Índice de Produtividade do Trabalho da Indústria Farmacêutica; DPIBR é a primeira diferença da PIBR; DCAMBIOR é a primeira diferença da CAMBIOR; DJUROSR é a primeira diferença da JUROS.

Os resultados do teste de PP realizados indicam a variável dependente IPROD se torna estacionária em primeira diferença (DIPROD), isto é, I(1). Do mesmo modo, os resultados dos testes para as variáveis independentes PIBR, CAMBIOR, JUROS e IPCAVAR indicam que as séries passam a ser estacionárias em primeira diferença (DPIBR, DCAMBIOR, JUROS, DIPCAVAR). Portanto, a modelagem posterior utilizará as séries em primeira diferença para todas as variáveis.

Identificação das ordens apropriadas para os processos AR e MA

Sabe-se que as funções de autocorrelação (AC) e de autocorrelação parcial (PAC) teóricas não são observadas, mas AC e PAC amostrais são conhecidas. Logo, deve-se buscar semelhanças entre as funções de autocorrelação teóricas e amostrais que sejam boas sugestões do processo que melhor explica a dinâmica da série em estudo.

A função de autocorrelação amostral estima a relação entre a covariância de k defasagens e a variância amostral de uma determinada série temporal. Dessa forma, é possível identificar o número de defasagens necessárias para que a série se comporte de forma estacionária, ou seja, apresente correlação nula. O correlograma amostral plota o resultado da razão entre a correlação das defasagens e a variância da série em relação ao número de defasagens.



Adicionalmente, a função de correlação parcial mostra que a série do índice de produtividade se torna estacionária em primeira diferença.

Após identificar a ordem de estacionariedade da série temporal e verificar a cointegração com as demais séries de variáveis exógenas, segue-se para o modelo econométrico, o qual segue a forma funcional de um modelo Autorregressivo Integrado de Médias Móveis (ARIMA), conforme definido nas Resoluções CMED nº 01/2015 e nº 05/2015.

O modelo ARIMA (p,d,q) é a agregação de um modelo autorregressivo (AR) com o modelo de médias móveis (MA), em séries cointegradas. Já sabemos que as séries são estacionárias e cointegradas em primeira diferença, logo são $I(1)$. A ordem de defasagem tanto do $AR(p)$ quanto da $MA(q)$ é sugerida pelo próprio pacote do R_Studio. O comando *auto.arima* testa todas as possíveis combinações de ordens do ARIMA que sejam factíveis, dado o número de variáveis exógenas, o tamanho da amostra e os graus de liberdade do modelo. A melhor combinação é aquela que minimiza os Critérios de Informação de Akaike (AIC).

O AIC é um teste de robustez que penaliza o uso de regressores no modelo, incluindo o intercepto e os componentes autorregressivos. Uma das vantagens do AIC é que o teste é válido também para previsões do modelo. Modelos com valores AIC mais baixos são preferíveis.

Foram testados diversos modelos, todos integrados de primeira ordem – $I(1)$, conforme requisito do método MQO, e é apresentado abaixo o modelo mais robusto de acordo com critérios econométricos, sem levantar críticas em relação ao sentido econômico das variáveis escolhidas para explicar o índice de produtividade.

A) Modelo ARIMA (0,1,1)

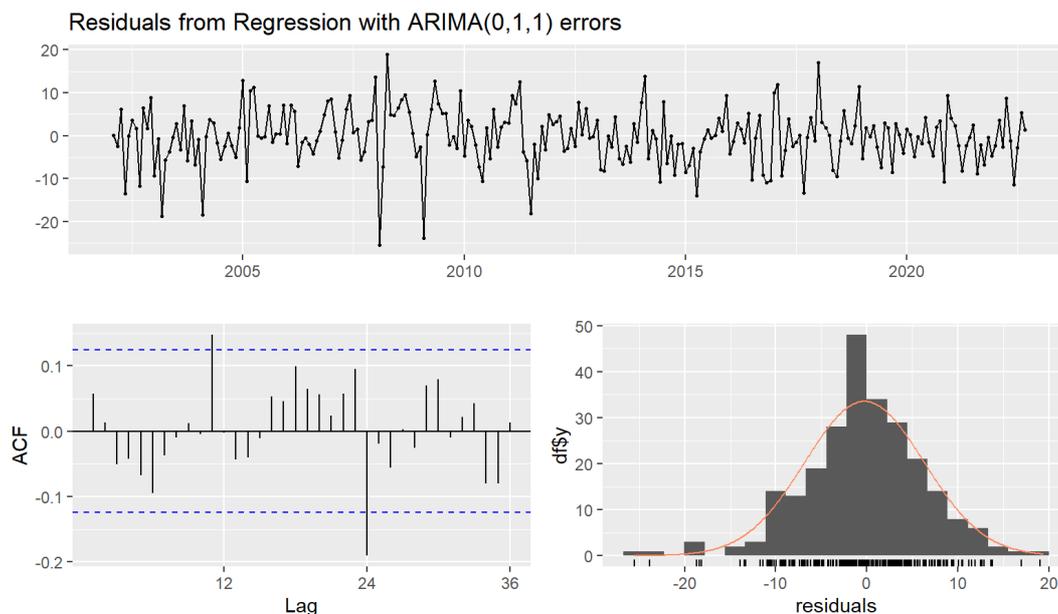
Tabela 2: Resultados do modelo ARIMA (0,1,1)

	ma1	IPCAVAR	JUROS	CAMBIOR	PIBR
Coefficientes	-0.7160	-0.1395	0.8743	0.6420	0e+00
s.e.	0.0533	1.1942	0.8918	4.8443	1e-04
$\sigma^2 = 44.02$; log likelihood = -815.73 AIC=1643.45 AICc=1643.8 BIC=1664.51					

O modelo ARIMA (0,1,1) foi o que apresentou o menor critério de Akaike e o maior número de coeficientes significativos. Todos os coeficientes dos componentes de média móvel foram significativos, para um intervalo de confiança de 90%.

A análise da função de autocorrelação dos resíduos do modelo ARIMA (0,1,1) indica que os mesmos não estão correlacionados entre si, garantido a eficácia dos coeficientes estimados para o seguinte exercício de previsão do

Índice de Produtividade do Trabalho do Setor Farmacêutico.



B) Considerações sobre a evolução recente do Índice de Produtividade do Trabalho do Setor Farmacêutico

Considerando a metodologia utilizada para a construção do Índice de Produtividade do Trabalho do Setor Farmacêutico (variável endógena) definida no Apêndice II, a sua trajetória depende das seguintes variáveis: (i) Índice de Produção Física Industrial da indústria farmacêutica (IPF); (ii) Total de Empregados Admitidos; (iii) Total de Empregados Demitidos; (iv) Total de Horas Contratuais dos Admitidos; e (v) Total de Horas Contratuais dos Demitidos.

TABELA 3: Taxa de variação das variáveis Número de Admitidos, Demitidos e Horas Contratadas dos Admitidos e Demitidos

	PFI	Taxa Variação IPF	Total de Empregados Admitidos	Taxa Variação Empregados Admitidos	Total de Empregados Demitidos	Taxa Variação Empregados Demitidos	Total de Horas Contratuais dos Admitidos	Taxa Variação Horas Contratuais dos Admitidos	Total de Horas Contratuais dos Demitidos	Taxa Variação Horas Contratuais dos Demitidos	Saldo Admitidos	Taxa Variação Saldo Admitidos	Saldo Horas Admitidos	Taxa Variação Saldo Horas Admitidos
Julho 2007 a Junho 2008	83,00		2069		1646,5		87309		69033,5		422,5		18275,5	
Julho 2008 a Junho 2009	95,36	14,90%	2222,5	7,42%	1784	8,35%	93863	7,51%	74968,5	8,60%	438,5	3,79%	18894,5	3,39%
Julho 2009 a Junho 2010	95,34	-0,02%	2216,5	-0,27%	1737	-2,63%	93335,5	-0,56%	72838	-2,84%	479,5	9,35%	20497,5	8,48%
Julho 2010 a Junho 2011	99,44	4,30%	2416	9,00%	2161,5	24,44%	100653	7,84%	89355	22,68%	254,5	-46,92%	11298	-44,88%
Julho 2011 a Junho 2012	92,95	-6,53%	2995,5	23,99%	2214,5	2,45%	124529,5	23,72%	92096,5	3,07%	781	206,88%	32433	187,07%
Julho 2012 a Junho 2013	101,01	8,67%	2521	-15,84%	2146	-3,09%	104410,5	-16,16%	88328	-4,09%	375	-51,98%	16082,5	-50,41%
Julho 2013 a Junho 2014	95,92	-5,04%	2493	-1,11%	2134	-0,56%	103552	-0,82%	89352,5	1,16%	359	-4,27%	14199,5	-11,71%
Julho 2014 a Junho 2016	98,67	2,88%	2352,5	-5,64%	2093	-1,92%	96209	-7,09%	85469,5	-4,35%	259,5	-27,72%	10739,5	-24,37%
Julho 2015 a Junho 2016	93,89	-4,85%	1954	-16,94%	1837	-12,23%	79765,5	-17,09%	75028	-12,22%	117	-54,91%	4737,5	-55,89%
Julho 2016 a Junho 2017	82,57	-12,05%	1756	-10,13%	1825,5	-0,63%	71948,5	-9,80%	74089,5	-1,25%	-69,5	-159,40%	-2141	-145,19%
Julho 2017 a Junho 2018	79,73	-3,45%	1718,5	-2,14%	1602	-12,24%	70715,5	-1,71%	65029	-12,23%	116,5	-267,63%	5686,5	-365,60%
Julho 2018 a Junho 2019	81,58	2,32%	1928	12,19%	1569	-2,06%	78495,5	11,00%	64595,5	-0,67%	359	208,15%	13900	144,44%
Julho 2019 a Junho 2020	90,61	11,07%	1875,5	-2,72%	1411	-10,07%	77794,295	-0,89%	58058,645	-10,12%	464,5	29,39%	19735,65	41,98%
Julho 2020 a Junho 2021	87,23	-3,73%	2033,5	8,42%	1572,5	11,45%	85046,005	9,32%	64538,355	11,16%	461	-0,75%	20507,65	3,91%
Julho 2021 a Junho 2022	80,11	-8,16%	2301,5	13,18%	1812,5	15,26%	95286,945	12,04%	74125,02	14,85%	489	6,07%	21161,93	3,19%
Média	90,49		2190,20		1836,40		90860,92		75793,70		353,8		15067,22	

A análise das médias anuais para cada uma das variáveis referidas no parágrafo anterior demonstra que, de 2021 para 2022, o IPF caiu 8,16%. Por outro lado, a quantidade de empregados admitidos cresceu (13,18%), ainda que proporcionalmente um pouco menos que a quantidade de empregados demitidos (15,26%).

O saldo de horas contratadas no setor farmacêutico também apresentou uma variação positiva de 3,19% entre julho de 2021 e junho de 2022, valor bastante similar ao observado no período precedente, isto é, de julho de 2020 a junho de 2021 (3,91%).

Vale destacar que, tal como ocorreu no ano passado, os exercícios de previsão estatística realizados este ano foram impactados pelo choque exógeno derivado de certas restrições ainda vigentes no Brasil e em outros países para conter a propagação do Covid-19 e que afetou as variáveis macroeconômicas (preços, câmbio, juros e PIB) que são determinantes para a evolução do Índice de Produtividade.

C) Fator de Produtividade X

	IPFF		IPFF		IPFF		IPFF
2019-07-01	81,67	2020-07-01	75,10	2021-07-01	76,82	2022-07-01	66,58
2019-08-01	80,46	2020-08-01	71,33	2021-08-01	66,23	2022-08-01	72,98
2019-09-01	71,38	2020-09-01	76,39	2021-09-01	70,02	2022-09-01	70,39
2019-10-01	80,39	2020-10-01	78,54	2021-10-01	65,52	2022-10-01	69,04
2019-11-01	77,02	2020-11-01	65,45	2021-11-01	70,67	2022-11-01	68,95
2019-12-01	72,77	2020-12-01	82,59	2021-12-01	66,60	2022-12-01	68,61
2020-01-01	78,29	2021-01-01	80,15	2022-01-01	65,71	2023-01-01	68,42
2020-02-01	77,72	2021-02-01	79,22	2022-02-01	72,31	2023-02-01	68,87
2020-03-01	73,42	2021-03-01	75,76	2022-03-01	66,54	2023-03-01	69,45
2020-04-01	76,06	2021-04-01	68,88	2022-04-01	76,40	2023-04-01	68,93
2020-05-01	74,41	2021-05-01	72,10	2022-05-01	70,66	2023-05-01	68,38
2020-06-01	79,22	2021-06-01	74,07	2022-06-01	59,07	2023-06-01	66,00
Média	76,9010		74,9658		68,8797		68,8825
Diferença			-2,5166%		-8,12%		0,0041%

D) Scripts

```
> setwd("F:/SEAE/Saúde/Fator X/Fator X 2022")
> df <- read.csv("Dataset20221.csv", sep = ';', dec = '.')
> View(df)
> library(tseries)
> library("urca")
> library(forecast)
> library(fpp)
> library(tseries)
> library(lmtest)
> library(vars)
> library(tidyverse)
> str(df)
'data.frame': 249 obs. of 8 variables:
 $ data : chr "01/01/2002" "01/02/2002" "01/03/2002" "01/04/2002" ...
 $ IPCAVAR: num 0.52 0.36 0.6 0.8 0.21 ...
 $ JUOSR : num 10.62 10.66 10.18 9.63 9.84 ...
 $ CAMBIOR: num 2.37 2.41 2.33 2.29 2.45 ...
 $ PIBR : num 111793 110502 116709 117680 120523 ...
 $ PRODSFF: num 68.3 69.7 67.6 73.8 59.7 67.4 70.2 69.1 59.2 73 ...
 $ HORAS : num 12992090 13120927 13231013 13192543 13089805 ...
 $ IPFF : num 87.6 88.5 85.1 93.1 76 ...
```

```
> df$data <- as.Date(df$data)
> x = ur.pp(df$IPFF, type = c("Z-tau"), model = c("constant"))
> summary(x)
```

```
#####
# Phillips-Perron Unit Root Test #
#####
```

Test regression with intercept

```
Call:
lm(formula = y ~ y.l1)
```

Residuals:

```
Min 1Q Median 3Q Max
-31.4067 -4.8599 0.3283 5.0131 22.0915
```

Coefficients:

```
Estimate Std. Error t value Pr(>|t|)
(Intercept) 19.86630 3.53217 5.624 5.05e-08 ***
y.l1 0.76412 0.04141 18.451 < 2e-16 ***
```

Signif. codes:

0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 7.473 on 246 degrees of freedom
Multiple R-squared: 0.5805, Adjusted R-squared: 0.5788
F-statistic: 340.4 on 1 and 246 DF, p-value: < 2.2e-16
Value of test-statistic, type: Z-tau is: -5.3097

aux. Z statistics

Z-tau-mu 5.2401

Critical values for Z statistics:

1pct 5pct 10pct

critical values -3.458165 -2.873276 -2.572971

```
> x=ur.pp(df$IPFF, type = c("Z-tau"), model = c("trend"))  
> summary(x)
```

```
#####  
# Phillips-Perron Unit Root Test #  
#####
```

Test regression with intercept and trend

Call:

lm(formula = y ~ y.l1 + trend)

Residuals:

Min	1Q	Median	3Q	Max
-31.679	-4.584	0.353	4.874	21.623

Coefficients:

Estimate Std. Error t value Pr(>|t|)

(Intercept) 20.620224 3.585523 5.751 2.63e-08 ***

y.l1 0.755244 0.042045 17.963 < 2e-16 ***

trend -0.008013 0.006729 -1.191 0.235

Signif. codes:

0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 7.467 on 245 degrees of freedom
Multiple R-squared: 0.5829, Adjusted R-squared: 0.5795
F-statistic: 171.2 on 2 and 245 DF, p-value: < 2.2e-16
Value of test-statistic, type: Z-tau is: -5.4733

aux. Z statistics

Z-tau-mu 7.0685

Z-tau-beta -1.1804

Critical values for Z statistics:

1pct 5pct 10pct

critical values -3.998253 -3.429176 -3.137773

```
> x=ur.pp(df$PIBR, type = c("Z-tau"), model = c("constant"))  
> summary(x)
```

```
#####  
# Phillips-Perron Unit Root Test #  
#####
```

Test regression with intercept

Call:

lm(formula = y ~ y.l1)

Residuals:

Min	1Q	Median	3Q	Max
-22223.6	-3891.7	-355.9	3686.1	19404.0

Coefficients:

```
      Estimate Std. Error t value Pr(>|t|)
(Intercept) 4.444e+03 2.218e+03 2.004 0.0462 *
y.l1        9.784e-01 1.186e-02 82.489 <2e-16 ***
```

Signif. codes:

```
0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Residual standard error: 6946 on 246 degrees of freedom
Multiple R-squared: 0.9651, Adjusted R-squared: 0.965
F-statistic: 6804 on 1 and 246 DF, p-value: < 2.2e-16
Value of test-statistic, type: Z-tau is: -1.5129

aux. Z statistics

```
Z-tau-mu      1.8059
```

Critical values for Z statistics:

```
      1pct  5pct 10pct
critical values -3.458165 -2.873276 -2.572971
```

```
> x=ur.pp(df$PIBR, type = c("Z-tau"), model = c("trend"))
> summary(x)
```

```
#####
# Phillips-Perron Unit Root Test #
#####
```

Test regression with intercept and trend

```
Call:
lm(formula = y ~ y.l1 + trend)
```

Residuals:

```
      Min      1Q  Median      3Q      Max
-24203.2 -4088.3 -699.7  3292.1 19047.1
```

Coefficients:

```
      Estimate Std. Error t value Pr(>|t|)
(Intercept) 1.893e+04 5.117e+03 3.701 0.000266 ***
y.l1        8.992e-01 2.786e-02 32.280 < 2e-16 ***
trend      4.529e+01 1.447e+01 3.130 0.001959 **
```

Signif. codes:

```
0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Residual standard error: 6825 on 245 degrees of freedom
Multiple R-squared: 0.9665, Adjusted R-squared: 0.9662
F-statistic: 3529 on 2 and 245 DF, p-value: < 2.2e-16
Value of test-statistic, type: Z-tau is: -3.018

aux. Z statistics

```
Z-tau-mu      5.9818
Z-tau-beta    2.4997
```

Critical values for Z statistics:

```
      1pct  5pct 10pct
critical values -3.998253 -3.429176 -3.137773
```

```
> x=ur.pp(df$CAMBIOR, type = c("Z-tau"), model = c("constant"))
> summary(x)
```

```
#####
# Phillips-Perron Unit Root Test #
#####
```

Test regression with intercept

```
Call:
```

```
lm(formula = y ~ y.l1)
```

```
Residuals:
```

```
  Min      1Q  Median      3Q      Max
-0.31039 -0.04382 -0.00938  0.04045  0.42450
```

```
Coefficients:
```

```
      Estimate Std. Error t value Pr(>|t|)
(Intercept) 0.02340   0.02008   1.165   0.245
y.l1        0.98770   0.01038  95.148 <2e-16 ***
```

```
---
```

```
Signif. codes:
```

```
0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Residual standard error: 0.08565 on 246 degrees of freedom
```

```
Multiple R-squared: 0.9735, Adjusted R-squared: 0.9734
```

```
F-statistic: 9053 on 1 and 246 DF, p-value: < 2.2e-16
```

```
Value of test-statistic, type: Z-tau is: -1.5471
```

```
aux. Z statistics
```

```
Z-tau-mu      1.5088
```

```
Critical values for Z statistics:
```

```
      1pct   5pct  10pct
critical values -3.458165 -2.873276 -2.572971
```

```
> x=ur.pp(df$CAMBIOR, type = c("Z-tau"), model = c("trend"))
```

```
> summary(x)
```

```
#####
# Phillips-Perron Unit Root Test #
#####
```

```
Test regression with intercept and trend
```

```
Call:
```

```
lm(formula = y ~ y.l1 + trend)
```

```
Residuals:
```

```
  Min      1Q  Median      3Q      Max
-0.29882 -0.04411 -0.00824  0.03707  0.43666
```

```
Coefficients:
```

```
      Estimate Std. Error t value Pr(>|t|)
(Intercept) 2.276e-02 2.004e-02   1.135   0.257
y.l1        9.880e-01 1.036e-02  95.363 <2e-16 ***
trend       1.090e-04 7.582e-05   1.438   0.152
```

```
---
```

```
Signif. codes:
```

```
0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Residual standard error: 0.08547 on 245 degrees of freedom
```

```
Multiple R-squared: 0.9738, Adjusted R-squared: 0.9736
```

```
F-statistic: 4547 on 2 and 245 DF, p-value: < 2.2e-16
```

```
Value of test-statistic, type: Z-tau is: -1.5025
```

```
aux. Z statistics
```

```
Z-tau-mu      0.3489
```

```
Z-tau-beta    1.1587
```

```
Critical values for Z statistics:
```

```
      1pct   5pct  10pct
critical values -3.998253 -3.429176 -3.137773
```

```
> x=ur.pp(df$JUROSUR, type = c("Z-tau"), model = c("constant"))
```

```
> summary(x)
```

```
#####  
# Phillips-Perron Unit Root Test #  
#####
```

Test regression with intercept

Call:
lm(formula = y ~ y.l1)

Residuals:

Min	1Q	Median	3Q	Max
-2.16632	-0.28502	-0.03296	0.24630	1.86278

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	0.052151	0.055521	0.939	0.349
y.l1	0.985819	0.008889	110.897	<2e-16 ***

Signif. codes:
0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.5281 on 246 degrees of freedom
Multiple R-squared: 0.9804, Adjusted R-squared: 0.9803
F-statistic: 1.23e+04 on 1 and 246 DF, p-value: < 2.2e-16
Value of test-statistic, type: Z-tau is: -1.9269

aux. Z statistics
Z-tau-mu 1.3047

Critical values for Z statistics:
1pct 5pct 10pct
critical values -3.458165 -2.873276 -2.572971

```
> x=ur.pp(df$JUOSR, type = c("Z-tau"), model = c("trend"))  
> summary(x)
```

```
#####  
# Phillips-Perron Unit Root Test #  
#####
```

Test regression with intercept and trend

Call:
lm(formula = y ~ y.l1 + trend)

Residuals:

Min	1Q	Median	3Q	Max
-2.15804	-0.28460	-0.03561	0.24675	1.85575

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	0.0425311	0.0860471	0.494	0.622
y.l1	0.9877389	0.0158444	62.340	<2e-16 ***
trend	0.0001224	0.0008349	0.147	0.884

Signif. codes:
0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.5292 on 245 degrees of freedom
Multiple R-squared: 0.9804, Adjusted R-squared: 0.9802
F-statistic: 6125 on 2 and 245 DF, p-value: < 2.2e-16
Value of test-statistic, type: Z-tau is: -1.9558

aux. Z statistics
Z-tau-mu -0.9546
Z-tau-beta -1.0439

Critical values for Z statistics:

1pct 5pct 10pct
critical values -3.998253 -3.429176 -3.137773

```
> x=ur.pp(df$IPCAVAR, type = c("Z-tau"), model = c("constant"))  
> summary(x)
```

```
#####  
# Phillips-Perron Unit Root Test #  
#####
```

Test regression with intercept

Call:
lm(formula = y ~ y.l1)

Residuals:

Min	1Q	Median	3Q	Max
-1.29398	-0.15618	-0.01162	0.15072	1.97742

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	0.16512	0.03127	5.281	2.82e-07 ***
y.l1	0.66988	0.04801	13.954	< 2e-16 ***

Signif. codes:

0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.3062 on 246 degrees of freedom
Multiple R-squared: 0.4418, Adjusted R-squared: 0.4395
F-statistic: 194.7 on 1 and 246 DF, p-value: < 2.2e-16
Value of test-statistic, type: Z-tau is: -6.9696

aux. Z statistics
Z-tau-mu 5.355

Critical values for Z statistics:

1pct 5pct 10pct
critical values -3.458165 -2.873276 -2.572971

```
> x=ur.pp(df$IPCAVAR, type = c("Z-tau"), model = c("trend"))  
> summary(x)
```

```
#####  
# Phillips-Perron Unit Root Test #  
#####
```

Test regression with intercept and trend

Call:
lm(formula = y ~ y.l1 + trend)

Residuals:

Min	1Q	Median	3Q	Max
-1.25806	-0.14993	-0.01497	0.15768	1.94896

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	0.1681561	0.0313911	5.357	1.95e-07 ***
y.l1	0.6642082	0.0482955	13.753	< 2e-16 ***
trend	-0.0002882	0.0002732	-1.055	0.293

Signif. codes:

0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.3061 on 245 degrees of freedom
Multiple R-squared: 0.4443, Adjusted R-squared: 0.4398
F-statistic: 97.96 on 2 and 245 DF, p-value: < 2.2e-16
Value of test-statistic, type: Z-tau is: -7.0466

```
aux. Z statistics
Z-tau-mu      5.0810
Z-tau-beta   -1.0608
```

Critical values for Z statistics:

```
      1pct  5pct  10pct
critical values -3.998253 -3.429176 -3.137773
```

```
> x=ur.pp(diff(df$IPFF), type = c("Z-tau"), model = c("constant"))
> summary(x)
```

```
#####
# Phillips-Perron Unit Root Test #
#####
```

Test regression with intercept

```
Call:
lm(formula = y ~ y.l1)
```

Residuals:

```
      Min      1Q  Median      3Q      Max
-29.9013 -3.9909  0.1111  4.6725  29.2400
```

Coefficients:

```
      Estimate Std. Error t value Pr(>|t|)
(Intercept) -0.10038  0.45029  -0.223  0.824
y.l1        -0.45930  0.05676  -8.092 2.74e-14 ***
```

Signif. codes:

```
0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Residual standard error: 7.077 on 245 degrees of freedom
Multiple R-squared:  0.2109, Adjusted R-squared:  0.2077
F-statistic: 65.47 on 1 and 245 DF, p-value: 2.744e-14
Value of test-statistic, type: Z-tau is: -33.0418
```

```
aux. Z statistics
Z-tau-mu      -0.2832
```

Critical values for Z statistics:

```
      1pct  5pct  10pct
critical values -3.458267 -2.873322 -2.572995
```

```
> x=ur.pp(diff(df$IPFF), type = c("Z-tau"), model = c("trend"))
> summary(x)
```

```
#####
# Phillips-Perron Unit Root Test #
#####
```

Test regression with intercept and trend

```
Call:
lm(formula = y ~ y.l1 + trend)
```

Residuals:

```
      Min      1Q  Median      3Q      Max
-29.9717 -4.0283  0.0509  4.6650  29.1723
```

Coefficients:

```
      Estimate Std. Error t value Pr(>|t|)
(Intercept) -0.099693  0.451184  -0.221  0.825
y.l1        -0.459394  0.056875  -8.077 3.05e-14 ***
trend       -0.001375  0.006328  -0.217  0.828
```

Signif. codes:

```
0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Residual standard error: 7.091 on 244 degrees of freedom
Multiple R-squared: 0.211, Adjusted R-squared: 0.2046
F-statistic: 32.63 on 2 and 244 DF, p-value: 2.761e-13
Value of test-statistic, type: Z-tau is: -33.0125

aux. Z statistics

Z-tau-mu -0.3919
Z-tau-beta -0.2765

Critical values for Z statistics:

1pct 5pct 10pct
critical values -3.998395 -3.429244 -3.137814

```
> x=ur.pp(diff(df$PIBR), type = c("Z-tau"), model = c("constant"))  
> summary(x)
```

```
#####  
# Phillips-Perron Unit Root Test #  
#####
```

Test regression with intercept

Call:
lm(formula = y ~ y.l1)

Residuals:

Min	1Q	Median	3Q	Max
-22047.7	-4267.3	-27.6	3545.5	19433.1

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	581.41690	440.30237	1.32	0.1879
y.l1	-0.17289	0.06311	-2.74	0.0066 **

Signif. codes:
0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 6901 on 245 degrees of freedom
Multiple R-squared: 0.02972, Adjusted R-squared: 0.02576
F-statistic: 7.505 on 1 and 245 DF, p-value: 0.006604
Value of test-statistic, type: Z-tau is: -20.8045

aux. Z statistics

Z-tau-mu 1.4822

Critical values for Z statistics:

1pct 5pct 10pct
critical values -3.458267 -2.873322 -2.572995

```
> x=ur.pp(diff(df$PIBR), type = c("Z-tau"), model = c("trend"))  
> summary(x)
```

```
#####  
# Phillips-Perron Unit Root Test #  
#####
```

Test regression with intercept and trend

Call:
lm(formula = y ~ y.l1 + trend)

Residuals:

Min	1Q	Median	3Q	Max
-21789.7	-4299.3	-107.3	3650.3	19753.4

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	582.99636	441.04210	1.322	0.18745

```
y.l1      -0.17331  0.06322 -2.741 0.00657 **
trend     -2.72353  6.16893 -0.441 0.65925
```

Signif. codes:

0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 6912 on 244 degrees of freedom
Multiple R-squared: 0.0305, Adjusted R-squared: 0.02255
F-statistic: 3.838 on 2 and 244 DF, p-value: 0.02285
Value of test-statistic, type: Z-tau is: -20.7969

aux. Z statistics

```
Z-tau-mu      2.2612
Z-tau-beta    -0.4895
```

Critical values for Z statistics:

```
      1pct  5pct 10pct
critical values -3.998395 -3.429244 -3.137814
```

```
> x=ur.pp(diff(df$CAMBIOR), type = c("Z-tau"), model = c("constant"))
> summary(x)
```

```
#####
# Phillips-Perron Unit Root Test #
#####
```

Test regression with intercept

```
Call:
lm(formula = y ~ y.l1)
```

Residuals:

```
      Min       1Q   Median       3Q      Max
-0.41664 -0.04213 -0.00479  0.03516  0.35585
```

Coefficients:

```
      Estimate Std. Error t value Pr(>|t|)
(Intercept) 0.0002875 0.0052988  0.054  0.957
y.l1         0.2514359 0.0618780  4.063 6.52e-05 ***
```

Signif. codes:

0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.08328 on 245 degrees of freedom
Multiple R-squared: 0.06314, Adjusted R-squared: 0.05931
F-statistic: 16.51 on 1 and 245 DF, p-value: 6.516e-05
Value of test-statistic, type: Z-tau is: -12.1522

aux. Z statistics

```
Z-tau-mu      0.0544
```

Critical values for Z statistics:

```
      1pct  5pct 10pct
critical values -3.458267 -2.873322 -2.572995
```

```
> x=ur.pp(diff(df$CAMBIOR), type = c("Z-tau"), model = c("trend"))
> summary(x)
```

```
#####
# Phillips-Perron Unit Root Test #
#####
```

Test regression with intercept and trend

```
Call:
lm(formula = y ~ y.l1 + trend)
```

Residuals:

```
Min 1Q Median 3Q Max
-0.40361 -0.03909 -0.00237 0.03164 0.36764
```

Coefficients:

```
Estimate Std. Error t value Pr(>|t|)
(Intercept) 2.442e-04 5.294e-03 0.046 0.963240
y.l1 2.448e-01 6.206e-02 3.945 0.000105 ***
trend 8.981e-05 7.454e-05 1.205 0.229393
---
```

Signif. codes:

```
0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Residual standard error: 0.0832 on 244 degrees of freedom
Multiple R-squared: 0.06868, Adjusted R-squared: 0.06105
F-statistic: 8.997 on 2 and 244 DF, p-value: 0.0001699
Value of test-statistic, type: Z-tau is: -12.1991

aux. Z statistics

```
Z-tau-mu 0.0450
Z-tau-beta 1.2077
```

Critical values for Z statistics:

```
1pct 5pct 10pct
critical values -3.998395 -3.429244 -3.137814
```

```
> x=ur.pp(diff(df$JUROSr), type = c("Z-tau"), model = c("constant"))
> summary(x)
```

```
#####
# Phillips-Perron Unit Root Test #
#####
```

Test regression with intercept

```
Call:
lm(formula = y ~ y.l1)
```

Residuals:

```
Min 1Q Median 3Q Max
-1.62379 -0.26421 -0.01517 0.24612 1.81802
```

Coefficients:

```
Estimate Std. Error t value Pr(>|t|)
(Intercept) -0.007237 0.030265 -0.239 0.811
y.l1 0.458222 0.058157 7.879 1.08e-13 ***
---
```

Signif. codes:

```
0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Residual standard error: 0.4751 on 245 degrees of freedom
Multiple R-squared: 0.2022, Adjusted R-squared: 0.1989
F-statistic: 62.08 on 1 and 245 DF, p-value: 1.076e-13
Value of test-statistic, type: Z-tau is: -9.2999

aux. Z statistics

```
Z-tau-mu -0.2383
```

Critical values for Z statistics:

```
1pct 5pct 10pct
critical values -3.458267 -2.873322 -2.572995
```

```
> x=ur.pp(diff(df$JUROSr), type = c("Z-tau"), model = c("trend"))
> summary(x)
```

```
#####
# Phillips-Perron Unit Root Test #
#####
```

Test regression with intercept and trend

Call:

```
lm(formula = y ~ y.l1 + trend)
```

Residuals:

```
   Min       1Q   Median       3Q      Max
-1.58285 -0.26706 -0.02242  0.24695  1.84993
```

Coefficients:

```
      Estimate Std. Error t value Pr(>|t|)
(Intercept) -0.0075616  0.0302626  -0.250   0.803
y.l1         0.4540278  0.0582889   7.789 1.93e-13 ***
trend        0.0004401  0.0004249   1.036   0.301
---

```

Signif. codes:

```
0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Residual standard error: 0.475 on 244 degrees of freedom
Multiple R-squared: 0.2057, Adjusted R-squared: 0.1991
F-statistic: 31.59 on 2 and 244 DF, p-value: 6.326e-13
Value of test-statistic, type: Z-tau is: -9.3523

aux. Z statistics

```
Z-tau-mu      -0.2522
Z-tau-beta    1.0351
```

Critical values for Z statistics:

```
      1pct   5pct  10pct
critical values -3.998395 -3.429244 -3.137814
```

```
> x=ur.kpss(df$IPFF, type = c("mu"))
> summary(x)
```

```
#####
# KPSS Unit Root Test #
#####
```

Test is of type: mu with 5 lags.

Value of test-statistic is: 0.9761

Critical value for a significance level of:

```
      10pct  5pct 2.5pct  1pct
critical values 0.347 0.463 0.574 0.739
```

```
> x=ur.kpss(df$IPFF, type = c("tau"))
> summary(x)
```

```
#####
# KPSS Unit Root Test #
#####
```

Test is of type: tau with 5 lags.

Value of test-statistic is: 0.8277

Critical value for a significance level of:

```
      10pct  5pct 2.5pct  1pct
critical values 0.119 0.146 0.176 0.216
```

```
> x=ur.kpss(diff(df$PIBR), type = c("mu"))
> summary(x)
```

```
#####
```

```
# KPSS Unit Root Test #
#####
```

Test is of type: mu with 5 lags.

Value of test-statistic is: 0.0767

Critical value for a significance level of:
10pct 5pct 2.5pct 1pct
critical values 0.347 0.463 0.574 0.739

```
> x=ur.kpss(diff(df$PIBR), type = c("tau"))
> summary(x)
```

```
#####
# KPSS Unit Root Test #
#####
```

Test is of type: tau with 5 lags.

Value of test-statistic is: 0.0313

Critical value for a significance level of:
10pct 5pct 2.5pct 1pct
critical values 0.119 0.146 0.176 0.216

```
> x=ur.kpss(diff(df$CAMBIOR), type = c("mu"))
> summary(x)
```

```
#####
# KPSS Unit Root Test #
#####
```

Test is of type: mu with 5 lags.

Value of test-statistic is: 0.2091

Critical value for a significance level of:
10pct 5pct 2.5pct 1pct
critical values 0.347 0.463 0.574 0.739

```
> x=ur.kpss(diff(df$CAMBIOR), type = c("tau"))
> summary(x)
```

```
#####
# KPSS Unit Root Test #
#####
```

Test is of type: tau with 5 lags.

Value of test-statistic is: 0.0369

Critical value for a significance level of:
10pct 5pct 2.5pct 1pct
critical values 0.119 0.146 0.176 0.216

```
> x=ur.kpss(diff(df$JUROS), type = c("mu"))
> summary(x)
```

```
#####
# KPSS Unit Root Test #
#####
```

Test is of type: mu with 5 lags.

Value of test-statistic is: 0.1341

Critical value for a significance level of:

10pct 5pct 2.5pct 1pct

critical values 0.347 0.463 0.574 0.739

```
> x=ur.kpss(diff(df$JUROSr), type = c("tau"))
```

```
> summary(x)
```

```
#####
```

```
# KPSS Unit Root Test #
```

```
#####
```

Test is of type: tau with 5 lags.

Value of test-statistic is: 0.0724

Critical value for a significance level of:

10pct 5pct 2.5pct 1pct

critical values 0.119 0.146 0.176 0.216

```
> xreg <- cbind(ipcavar=diff(df$IPCAVAR), jurosr=diff(df$JUROSr),
```

```
+ cambior=diff(df$CAMBIOR), pibr=diff(df$PIBR))
```

```
> view(xreg)
```

```
> df<-df[-c(1),]
```

```
> IPFF<-ts(df$IPFF,start=c(2002,2),freq=12)
```

```
> view(IPFF)
```

```
> acf(IPFF,main="FAC")
```

```
> pacf(IPFF,main="FACP")
```

```
> acf(diff(IPFF),main="FAC")
```

```
> pacf(diff(IPFF),main="FACP")
```

```
> ggtsdisplay(df$IPFF,main="IPFF")
```

```
> ggtsdisplay(diff(df$IPFF),main="DIFFIPFF")
```

```
> ggtsdisplay(log(df$IPFF),main="LOGIPFF")
```

```
> #if(!require(devtools)) install.packages("devtools")
```

```
> #devtools::install_github("sinhrks/ggfortify")
```

```
> #install.packages("fpp2")
```

```
> #library(ggfortify)
```

```
> #library(fpp2)
```

```
> IPFF_time <- time(IPFF)
```

```
> view(IPFF_time)
```

```
> IPFF_lm <- lm(IPFF~IPFF_time)
```

```
> summary(IPFF_lm)
```

Call:

```
lm(formula = IPFF ~ IPFF_time)
```

Residuals:

```
Min 1Q Median 3Q Max
-28.803 -8.560 -1.444 8.915 30.704
```

Coefficients:

```
Estimate Std. Error t value Pr(>|t|)
(Intercept) 795.2915 242.9456 3.274 0.00121 **
IPFF_time -0.3532 0.1207 -2.926 0.00376 **
```

```
---
```

Signif. codes:

```
0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Residual standard error: 11.34 on 246 degrees of freedom

Multiple R-squared: 0.03363, Adjusted R-squared: 0.0297

F-statistic: 8.561 on 1 and 246 DF, p-value: 0.003755

```
> library(BETS)
```

```
> modArima <- auto.arima(IPFF,xreg=xreg,stepwise=FALSE,trace=TRUE,seasonal=F)
```

Fitting models using approximations to speed things up...

Regression with ARIMA(0,1,0)	errors : 1721.898
Regression with ARIMA(0,1,0)	errors : Inf
Regression with ARIMA(0,1,1)	errors : 1639.18
Regression with ARIMA(0,1,1)	errors : Inf
Regression with ARIMA(0,1,2)	errors : 1639.589
Regression with ARIMA(0,1,2)	errors : 1641.198
Regression with ARIMA(0,1,3)	errors : 1640.61
Regression with ARIMA(0,1,3)	errors : 1642.205
Regression with ARIMA(0,1,4)	errors : 1642.755
Regression with ARIMA(0,1,4)	errors : 1644.368
Regression with ARIMA(0,1,5)	errors : 1644.811
Regression with ARIMA(0,1,5)	errors : 1646.44
Regression with ARIMA(1,1,0)	errors : 1672.675
Regression with ARIMA(1,1,0)	errors : Inf
Regression with ARIMA(1,1,1)	errors : 1639.643
Regression with ARIMA(1,1,1)	errors : 1641.323
Regression with ARIMA(1,1,2)	errors : 1641.008
Regression with ARIMA(1,1,2)	errors : 1642.769
Regression with ARIMA(1,1,3)	errors : Inf
Regression with ARIMA(1,1,3)	errors : Inf
Regression with ARIMA(1,1,4)	errors : Inf
Regression with ARIMA(1,1,4)	errors : Inf
Regression with ARIMA(2,1,0)	errors : 1660.916
Regression with ARIMA(2,1,0)	errors : Inf
Regression with ARIMA(2,1,1)	errors : 1646.642
Regression with ARIMA(2,1,1)	errors : Inf
Regression with ARIMA(2,1,2)	errors : 1640.43
Regression with ARIMA(2,1,2)	errors : 1642.045
Regression with ARIMA(2,1,3)	errors : 1642.534
Regression with ARIMA(2,1,3)	errors : 1644.191
Regression with ARIMA(3,1,0)	errors : 1650.815
Regression with ARIMA(3,1,0)	errors : Inf
Regression with ARIMA(3,1,1)	errors : 1645.828
Regression with ARIMA(3,1,1)	errors : Inf
Regression with ARIMA(3,1,2)	errors : 1639.64
Regression with ARIMA(3,1,2)	errors : 1641.452
Regression with ARIMA(4,1,0)	errors : 1650.655
Regression with ARIMA(4,1,0)	errors : Inf
Regression with ARIMA(4,1,1)	errors : 1642.836
Regression with ARIMA(4,1,1)	errors : 1644.557
Regression with ARIMA(5,1,0)	errors : 1651.83
Regression with ARIMA(5,1,0)	errors : Inf

Now re-fitting the best model(s) without approximations...

Best model: Regression with ARIMA(0,1,1) errors

> summary(modArima)

Series: IPFF

Regression with ARIMA(0,1,1) errors

Coefficients:

mal	ipcavar	jurosr	cambior	pibr
-0.7160	-0.1395	0.8743	0.6420	0e+00
s.e.	0.0533	1.1942	0.8918	4.8443 1e-04

sigma² = 44.02: log likelihood = -815.73
 AIC=1643.45 AICc=1643.8 BIC=1664.51

Training set error measures:

	ME	RMSE	MAE	MPE
Training set	-0.2753829	6.554276	4.897161	-0.9038862
	MAPE	MASE	ACF1	
Training set	5.955682	0.6247368	0.05731957	

```
> autoplot(residuals(modArima))
> checkresiduals(modArima)
```

Ljung-Box test

data: Residuals from Regression with ARIMA(0,1,1) errors
Q* = 32.031, df = 23, p-value = 0.0995

Model df: 1. Total lags used: 24

```
> expected_modArima <- matrix(c(0.780,0.000,0.000,0.000,0.000,0.000,0.000,0.000,0.000,
+ 0.801,0.583,0.256,0.053,0.557,1.217,0.621,-0.021,-2.685,
+ 0.152,0.155,0.051,0.052,0.053,0.054,0.055,0.056,-0.025,
+ 6263.261,6432.369,6606.043,6281.857,6438.904,6599.876,6764.873,6933.995,7107.345),
+ nrow=9,ncol=4)
> dimnames(expected_modArima) <- list(c("out22", "nov22", "dez22", "jan23", "fev23", "mar23", "abr23", "mai23",
"jun23"),
+ c("ipcavar", "jurosr", "cambior", "pibr"))
> view(expected_modArima)
> myforecast=forecast(modArima,
+ xreg=expected_modArima,
+ level=c(95),
+ h=9)
> print(summary(myforecast))
```

Forecast method: Regression with ARIMA(0,1,1) errors

Model Information:

Series: IPFF

Regression with ARIMA(0,1,1) errors

Coefficients:

	mal	ipcavar	jurosr	cambior	pibr
	-0.7160	-0.1395	0.8743	0.6420	0e+00
s.e.	0.0533	1.1942	0.8918	4.8443	1e-04

$\sigma^2 = 44.02$: log likelihood = -815.73
AIC=1643.45 AICc=1643.8 BIC=1664.51

Error measures:

	ME	RMSE	MAE	MPE
Training set	-0.2753829	6.554276	4.897161	-0.9038862
	MAPE	MASE	ACF1	
Training set	5.955682	0.6247368	0.05731957	

Forecasts:

	Point Forecast	Lo 95	Hi 95
Oct 2022	69.03512	56.03070	82.03954
Nov 2022	68.95976	55.44111	82.47841
Dec 2022	68.61177	54.59775	82.62580
Jan 2023	68.42625	53.93378	82.91872
Feb 2023	68.87172	53.91610	83.82735
Mar 2023	69.45369	54.04883	84.85855
Apr 2023	68.93770	53.09635	84.77906
May 2023	68.38161	52.11547	84.64776
Jun 2023	66.00526	49.32514	82.68538

```
> autoplot(myforecast)
```

[1] A Resolução CMED nº 05/2015 retifica os itens 2.2.1 e 2.2.3.1.1 da resolução CMED 01/2015.

[2] A Resolução CMED nº 01/2015 determina a utilização do Índice Nacional de Preços ao Consumidor Amplo (IPCA), calculado pelo Instituto Brasileiro de Geografia e Estatística (IBGE), acumulado no período dos doze meses anteriores à publicação do ajuste de preços.





Documento assinado eletronicamente por **Andrey Vilas Boas de Freitas**, **Subsecretário de Advocacia da Concorrência**, em 02/12/2022, às 19:04, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Mariana Piccoli Lins Cavalcanti**, **Coordenador(a)-Geral**, em 08/12/2022, às 11:50, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.economia.gov.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **29251115** e o código CRC **10618A28**.
