



UNIVERSIDADE DE BRASÍLIA
FACULDADE DE ADMINISTRAÇÃO, CONTABILIDADE E ECONOMIA (FACE)
DEPARTAMENTO DE ECONOMIA

**ANÁLISE DE DESEMPENHO: UMA COMPARAÇÃO DE MÉTODOS DE
PROJEÇÃO PARA A TAXA DE DESOCUPAÇÃO BRASILEIRA**

ISABELLA BIANCHI

ORIENTADOR: MANOEL CARLOS PIRES
OUTUBRO, 2022

Análise de desempenho: uma comparação de métodos de projeção para a Taxa de Desocupação brasileira

Monografia apresentada ao Departamento de Economia da Universidade de Brasília, como requisito parcial à obtenção do grau de bacharelado em Ciências Econômicas.

Orientador: Manoel Carlos Pires

Brasília
2022

ISABELLA BIANCHI

Análise de desempenho: uma comparação de métodos de projeção para a Taxa de Desocupação brasileira

A Comissão Examinadora, abaixo identificada, aprova o Trabalho de Conclusão de Curso de Ciências Econômicas da Universidade de Brasília do (a) aluno (a)

Isabella Bianchi

Manoel Carlos Pires
Departamento de Economia (FACE)

Nelson Barbosa
Departamento de Economia (FACE)

Larissa Maria Nocko
Confederação Nacional da Indústria (CNI)

Brasília, 06 de outubro de 2022

Resumo

A monografia teve por objetivo a comparação do desempenho de projeções realizadas para a Taxa de Desocupação brasileira a partir de diferentes métodos, e, considerando também, distintos períodos de tempo. As metodologias de projeção incluídas são as de modelos Autorregressivos Integrados de Médias Móveis (ARIMA), Autorregressivos de Defasagens Distribuídas (ARDL), Autorregressivos Vetoriais (VAR), e o método de suavização exponencial de Holt-Winters. Como principais características observadas, se destacam a grande influência dos dados mais recentes para os métodos univariados, ARIMA e Holt-Winters, além da dificuldade de projeção de mudanças no nível da série, fator de grande influência na qualidade final das projeções, a depender dos períodos para os quais são estimadas. Para os métodos multivariados, se destacam a influência sofrida pelas hipóteses adotadas para a realização da estimação dos valores futuros de variáveis exógenas, no caso do modelo estimado pelo método ARDL, e a dificuldade de estimação das relações endógenas no caso do método VAR.

Palavras-chave: Séries de tempo; ARIMA; ARDL; VAR; Holt-Winters.

Abstract

The paper's aim was to compare the performance of projections made for the Brazilian Unemployment Rate through different methods and time periods. The included projection methodologies are the Autoregressive Integrated Moving Average (ARIMA), Autoregressive Distributed Lag (ARDL), Vector Autoregression (VAR) and Holt-Winters exponential smoothing method. For univariate methods, such as ARIMA and Holt-Winters, the main observed features are the influence of most recent data on projections and the methods' level change generation incapability, a factor that influences the final quality of projections, depending on the moment for which they were estimated. For multivariate methods, the effects generated by some hypothesis, adopted in order to estimate future values of exogenous variables, for the ARDL method, and the endogenous relationship estimating difficulty, for the VAR method, stands out.

Key words: Time series; ARIMA; ARDL; VAR; Holt-Winters.

Agradecimentos

Agradeço imensamente à minha família, em especial aos meus pais, Tais e José Carlos, e à minha irmã Larissa, por todo o suporte e amor. Também não poderia deixar de fora os inúmeros amigos que colecionei ao longo do caminho. Aos amigos de São Paulo, que mesmo à distância se mantiveram por perto, e aos amigos de Brasília, que tanto me deram suporte e incentivo ao longo desses anos. Luiza, Beatriz, Amanda(s), Antônio, Gabriela, Ada, Bianca, Letícia e Felipe, não teria sido o mesmo sem vocês.

Agradeço também aos professores e funcionários da Universidade de Brasília, especialmente ao querido professor e orientador Manoel Carlos Pires, por todos os ensinamentos. Agradeço também aos líderes e colegas de trabalho, que tanto contribuíram com a minha formação, especialmente à Larissa, que me proporcionou o primeiro contato com a econometria de séries de tempo.

SUMÁRIO

1. Introdução	6
1.1. Introdução	6
2. Metodologia	8
2.1. ARIMA	9
2.2. ARDL	10
2.3. VAR	11
2.4. Holt-Winters	12
3. Escolha e tratamento dos dados	13
3.1. Escolha dos dados	13
3.2. Tratamento dos dados	15
4. Modelos	17
4.1. ARIMA	17
4.2. ARDL	19
4.3. VAR	20
4.4. Holt-Winters	21
5. Comparação entre os resultados	22
5.1. Amostra de treino	23
5.2. Amostra completa	24
6. Conclusão	26
7. Referências	28
Apêndice	28

1. Introdução

1.1. Introdução

Análises de cenário e conjuntura são amplamente difundidas nas ciências econômicas. O entendimento e identificação da evolução de variáveis que compõem a economia, de forma quantitativa, bem como dos impactos que afetam o comportamento dessas séries, fornecem insumos para as análises econômicas. Os estudos a respeito da evolução do emprego também são amplamente difundidos, e a predição das suas taxas possui grande relevância para a consolidação de perspectivas nas mais diversas áreas da economia.

A Taxa de Desocupação brasileira, ilustrada no Gráfico 1, apresenta diferentes padrões de evolução ao longo do tempo. Entre o final de 2014 e início de 2017, a série é dominada por um crescimento contínuo. Após esse período, a série passa a apresentar um recuo moderado em sua evolução, com leve trajetória de queda até o início de 2020, período de surgimento dos primeiros casos de COVID-19 no país. Após a realização do choque, a Taxa de Desocupação atinge seu ponto máximo na série histórica, de 14,9% da População Economicamente Ativa (PEA), no 3º trimestre de 2020 e 1º trimestre de 2021.

GRÁFICO 1 - Evolução da série histórica da Taxa de Desocupação (%)



Os choques recentes na taxa de desemprego nacional dificultam a modelagem da variável, fator que afeta também a capacidade preditiva de diferentes modelos econométricos. A partir da comparação entre modelos e seus resultados, podemos visualizar parte do impacto

das mudanças de cenário dos últimos anos, a fim de analisar a adequação de cada um deles para produzir projeções no presente momento.

Vale ressaltar que no início da pandemia foi criado o Programa Emergencial de Preservação do Emprego e da Renda, que possibilitou a flexibilização de contratos trabalhistas formais, permitindo a negociação de redução das jornadas de trabalho, com redução proporcional das remunerações, e afastamentos das atividades sem desligamento da função.

Mesmo com o efeito de atenuação da redução do emprego formal, gerado pela medida, o contingente de estoque de trabalhadores registrados no Novo Cadastro Geral de Empregados e Desempregados (Novo-CAGED) apresentou quedas consecutivas entre março e junho de 2020, ponto em que atinge o ponto mínimo da série, que tem início em janeiro de 2021.

Além da mudança na taxa global de desocupação, após a pandemia também é possível observar mudanças nos quadros de composição de diversos indicadores relacionados ao emprego, como expansão do emprego informal e da subocupação. Tais mudanças também refletem parte da contração da renda média do trabalho, que no 4º trimestre de 2021 atingiu a mínima histórica da série.

A partir do segundo semestre de 2021, a Taxa de Desocupação apresenta quedas consecutiva, de forma que se encontra abaixo do patamar estabelecido anteriormente à pandemia. No 2º trimestre de 2022, a desocupação atinge os 9,3%, menor valor desde o 1º trimestre de 2016, período em que a desocupação representava 11,1% da População em Idade Ativa.

O presente trabalho tem por objetivo principal a elaboração e comparação de modelagens da taxa de desemprego no Brasil, e a realização de suas respectivas projeções, através da aplicação dos diferentes métodos econométricos para séries de tempo, além da comparação entre as capacidades preditivas dos diferentes modelos.

A aplicação dos métodos econométricos de séries de tempo tem como intuito a estimação de equações com componentes estocásticos e a análise da relação entre diferentes variáveis de um modelo.

Apesar das delimitações a respeito da dinâmica entre desocupação e outras variáveis, explicitadas por equações macroeconômicas, a literatura conta com diversos exemplos de

elaboração de modelos preditivos para a variável, de forma que não foi possível identificar um padrão bem definido em relação as estimações usualmente realizadas.

Apesar da possibilidade de alimentação dos modelos com variáveis adicionais, que representam essas relações teóricas entre as variáveis, a aplicação dos métodos preditivos abre possibilidade de abordagens diversas, dado que a estimação voltada para a predição não exige a determinação de todas as relações estruturais de composição da variável, fator que justifica a diversidade dos métodos e adaptações realizadas para cada estimação.

2. Metodologia

Antes de tratarmos especificamente dos métodos econométricos utilizado para cada modelagem, precisamos nos debruçar sobre os conceitos de estacionariedade e convergência, e sobre a importância dessas propriedades estatísticas, que possibilitam a realização das modelagens e projeções das séries de tempo.

Uma série de tempo é dita estacionária quando a esperança do valor assumido pela variável em qualquer momento do tempo for igual à média, e a média, variância e covariância não forem afetados por mudanças no tempo, ou seja, quando essas estatísticas assumirem constância. De maneira formal, podemos especificar essas condições da seguinte forma (ENDERS, 2015, p.51-53):

- $E(y_t) = E(y_{t-s}) = \mu$;
- $E[(y_t - \mu)^2] = E[(y_{t-s} - \mu)^2] = \sigma_y^2$;
 - $\therefore \text{var}(y_t) = \text{var}(y_{t-s}) = \sigma_y^2$;
- $E[(y_t - \mu)(y_{t-s} - \mu)] = E[(y_{t-j} - \mu)(y_{t-j-s} - \mu)] = \gamma_s$;
 - $\therefore \text{cov}(y_t, y_{t-s}) = \text{cov}(y_{t-j}, y_{t-j-s}) = \gamma_s$;

Onde μ , σ_y^2 e γ_s são constantes.

Portanto, as séries de tempo são determinadas estacionarias quando possuem funções de densidade probabilísticas com igual distribuição para qualquer período t, mesmo admitindo diferentes realizações de valores ao longo da série. Portanto, as realizações dos valores não dependem do tempo, são independentes, e a trajetória da série mantém um comportamento padrão com características constantes ao longo do tempo, de forma que os valores circulem de forma bem-comportada em torno de uma média ou de uma tendência.

Segundo Enders, as propriedades estatísticas da estacionariedade garantem que as raízes de solução de uma equação assumam valores dentro do círculo unitário, de forma que seja estacionária (2015, p.58-60). A existência de raízes de solução que assumem valores menores que um garante também a propriedade de convergência da série, uma vez que permitem a dissipação dos choques aleatórios ao longo do tempo.

2.1. ARIMA

Em 1970, George Box e Gwilym Jenkins publicam a primeira versão do livro *Time Series Analysis: Forecasting and Control*, que consolida a metodologia de aplicação dos Modelos Autorregressivos de Médias Móveis, conhecidos como ARIMA, partindo da adaptação de diferentes ferramentas matemáticas e estatísticas para as ciências econômicas. O método de elaboração prática dos modelos ARIMA também é conhecido como Metodologia Box-Jenkins, em homenagem aos estatísticos.

Um dos principais objetivos da metodologia é o de modelar séries de tempo de uma forma simplificada, mas que, simultaneamente, proporcione boa capacidade preditiva em relação a outros modelos. Os modelos ARIMA possibilitam o entendimento do fator gerador da série de tempo, além disso, quando realizamos projeções, podemos ver como o modelo utiliza os valores e comportamentos passados para calcular a variância dos erros da projeção, de forma a determinar os limites em que os valores futuros podem assumir (BOX & JENKINS, 1970, p. viii).

Os modelos ARIMA são constituídos de uma ordem autorregressiva, identificados como AR(p), uma ordem de integração, denominada por I(d), e uma ordem de médias móveis, identificada como AM(q).

A estrutura autorregressiva do modelo mensura a influência dos valores defasados de uma série na composição da realização do seu valor contemporâneo. Matematicamente, podemos identificar um termo AR(p) de uma função através da diferenciação de ordem p de uma função do tempo:

$$y_t = \alpha_0 + \sum_{i=1}^p \alpha_i y_{t-i} + x_t$$

De tal forma, representamos a composição da variável em determinado momento do tempo a partir da soma de uma constante α_0 , que representa o intercepto da função, do somatório de um peso α_i aplicado ao valor defasado da variável, dado por y_{t-i} , e do termo x_t , conhecido como *forcing process*.

O forcing process pode ser representado por um processo MA de ordem (q), onde a estrutura de médias móveis do modelo mensura os impactos de um termo estocástico sobre a realização dos valores da série.

$$y_t = \alpha_0 + \sum_{i=1}^p \alpha_i y_{t-i} + \sum_{i=0}^q \beta_i \varepsilon_{t-i}$$

Unindo os processos autorregressivo e de médias móveis, quando trabalhamos com séries estacionárias, temos os modelos ARMA. Os modelos ARIMA se diferenciam por possuir ordem de integração, ou seja, quando a diferenciação da série se faz necessária para eliminar a fonte de não estacionariedade, de forma que a ordem de integração do modelo representa o número de diferenciações necessária para que a propriedade estatística seja alcançada.

2.2. ARDL

Os modelos Autorregressivos de Defasagens Distribuídas, ou ARDL são modelos multivariados, pois incluem variáveis independentes que são utilizadas como regressores do modelo, ou seja, são utilizadas para explicar o comportamento da série modelada. De tal forma, podemos utilizar tanto os valores defasados da própria série, quanto os valores contemporâneos e defasados de variáveis exógenas. Os modelos ARDL podem ser representados como:

$$y_t = \alpha_0 + \sum_{i=1}^p \alpha_i y_{t-i} + \sum_{i=0}^n c_i z_{t-i} + e_{t-i}$$

Esse tipo de modelo não consegue explicitar matematicamente as possíveis relações de endogeneidade entre variáveis, ou seja, as relações são delimitadas como unilaterais, de forma que as mudanças na variável modelada não gerem efeitos nas variáveis explicativas como resposta, assume, portanto, a hipótese de exogeneidade de z. No caso de variáveis macroeconômicas, essa pode ser uma hipótese restritiva, uma vez que nem sempre pode ser confirmada.

O modelo usualmente apresenta maior capacidade explicativa em comparação com modelos univariados, como ARIMA e Holt-Winters, que não utilizam outras variáveis como fatores explicativos da série. Apesar desse ganho proporcionado pela adição de demais variáveis, a qualidade da estimação dos valores futuros de y depende da capacidade de previsão dos valores futuros das variáveis exógenas, uma vez que não podem ser estimadas pelo próprio modelo, e, portanto, precisam ser projetadas isoladamente. De tal forma, a utilização de valores estimados de forma recursiva, em um novo sistema de estimação, gera um acúmulo dos componentes de erros, fator que pode afetar tanto a qualidade final da projeção quanto enviesar a estimação.

2.3. VAR

Com muita frequência, a macroeconomia se depara com a endogeneidade. Esse fator implica que as variáveis podem se definir de forma conjunta ou se afetarem mutuamente. Os modelos Vetoriais Autorregressivos possibilitam a especificação dessas relações entre as variáveis contemporâneas, suas próprias defasagens e as defasagens das outras variáveis do modelo.

Apesar da possibilidade de incorporação das múltiplas relações entre as variáveis, os modelos VAR apresentam problemas de especificação, ou seja, não é possível identificar os valores de forma isolada desses coeficientes. Isso acontece porque o modelo nos fornece mais variáveis do que equações, portanto, é necessário transformar a função em sua forma reduzida para que seja possível estimá-la. A forma reduzida de um VAR de ordem p assume forma:

$$\mathbf{y}_t = \sum_{i=1}^p A_i \mathbf{y}_{t-i} + C \mathbf{D}_t + \mathbf{u}_t$$

Onde p representa o número de defasagens adotadas no modelo e \mathbf{y}_t representa o vetor de variáveis endógenas para um determinado período t . A matriz A é composta pelos coeficientes que determinam a relação entre os vetores de defasagens e o vetor de valores contemporâneos das variáveis endógenas. A matriz C representa a relação do modelo com variáveis exógenas, contidas no vetor \mathbf{D} , e, por fim, \mathbf{u}_t representa o vetor de resíduos para cada um dos períodos.

A transformação da função em sua forma reduzida não permite a recuperação posterior dos parâmetros inicialmente especificados o que requer a identificação do modelo. A análise

dos resultados desse tipo de modelo pode ser feita através da análise do comportamento da função de impulso resposta do modelo, obtida a partir da simulação de um choque no valor contemporâneo de apenas uma das variáveis e, posteriormente, da mensuração das respostas geradas ao longo do tempo pela variação inicial.

Quando as séries modeladas apresentam padrão de estacionariedade, os multiplicadores do choque convergem para zero conforme o tempo aumenta, o que significa que os choques não possuem efeitos permanentes na série, e se dissipam ao longo do tempo. O rompimento desse requisito impossibilita a mensuração correta e a realização de projeções através desse método.

2.4. Holt-Winters

Os modelos do tipo ARIMA, ARDL e VAR são modelos econométricos de séries de tempo, em que à cada regressor é atribuído um coeficiente, ou seja, a relação matemática entre as variáveis explicativas e a dependente é explicitada pela magnitude desses coeficientes. Os métodos econométricos combinam os valores estimados para cada período das séries para estimar esses coeficientes.

Já o modelo Holt-Winters estima os valores para a série a partir de um procedimento de suavização exponencial. O modelo surge a partir da especificação dos movimentos de tendência, nível e sazonalidade como equações de suavização de um processo de suavização exponencial simples, e, portanto, é composto por quatro equações, uma para cada um dos respectivos componentes citados e uma equação de projeção.

Cada uma das equações realiza uma média ponderada das observações passadas para cada um dos componentes, ponderados por coeficientes que decrescem exponencialmente conforme se distanciam da observação estimada. Os coeficientes podem assumir valores entre 0 e 1 e representam o parâmetro de suavização. Valores mais próximos de 1 indicam que os pesos dados às observações passadas diminuem mais rapidamente ao longo dos períodos.

O modelo Holt-Winters pode assumir tanto uma forma aditiva quanto uma multiplicativa. Em sua forma aditiva, a sazonalidade evolui à uma frequência constante, portanto estima com mais precisão séries em que o componente apresenta magnitude estável ao longo do tempo. O modelo em sua forma aditiva é dado por:

$$y_{t+n} = E_t + nT_t + S_{t+n-p} + e_{t+n}$$

$$\begin{aligned}
T_t &= \beta(E_t - E_{t-1}) + (1 - \beta) T_{t-1} \\
E_t &= \alpha(y_t - S_{t-p}) + (1 - \alpha)(E_{t-1} + T_{t-1}) \\
S_t &= \gamma(y_t - E_t) + (1 - \gamma) S_{t-p}
\end{aligned}$$

Onde E_t representa o componente de ciclo, T_t representa a tendência, S_{t+n-p} representa a sazonalidade do mesmo período do ciclo anterior, e e_{t+n} representa o termo de erro. Em sua forma multiplicativa, a sazonalidade apresenta padrão de crescimento ao longo do tempo. O modelo em sua forma multiplicativa é dado por:

$$\begin{aligned}
y_{t+n} &= (E_t + nT_t)S_{t+n-p} + e_{t+n} \\
T_t &= \beta(E_t - E_{t-1}) + (1 - \beta) T_{t-1} \\
E_t &= \alpha(y_t/S_{t-p}) + (1 - \alpha)(E_{t-1} + T_{t-1}) \\
S_t &= \gamma(y_t/E_t) + (1 - \gamma) S_{t-p}
\end{aligned}$$

Onde α , β e γ representam os pesos atribuídos à cada fator, e assumem valores entre 0 e 1. Os modelos aditivos são utilizados quando o termo sazonal da série cresce com proporção estável ao longo do tempo, já os modelos multiplicativos são utilizados quando o efeito sazonal se intensifica, ou seja, atinge amplitudes cada vez maiores ao longo do tempo (LIMA et al., 2019).

3. Escolha e tratamento dos dados

De forma a preservar a comparabilidade entre os diferentes modelos, todos foram estimados com as séries originais, sem tratamentos de dessazonalização. Dado que o modelo de Holt-Winters trabalha com a especificação dos componentes de tendência, ciclo e sazonalidade, deve ser aplicado em séries com sazonalidade. O controle desse componente nas séries foi feito a partir da identificação e tratamento de raízes unitárias sazonais presentes. Já nos modelos que não apresentam identificação específica para sazonalidade, o controle foi feito a partir da introdução de dummies sazonais.

3.1. Escolha dos dados

Existem variadas séries de dados que expressam informações sobre a evolução do cenário de desemprego no Brasil. Com o intuito de agregar informações a respeito do desemprego formal e informal, a série escolhida como variável dependente dos modelos foi a taxa de desocupação, da Pesquisa Nacional por Amostra de Domicílios Contínua de divulgação

trimestral (PNADC/T), que considera o percentual de pessoas desocupadas em relação ao total de pessoas na força de trabalho. Pela metodologia da pesquisa, são consideradas ocupadas todas as pessoas com 14 anos ou mais, engajadas em empregos formais ou não. A categoria de pessoas na força de trabalho, por sua vez, considera a soma entre o contingente de população ocupada e o contingente de desocupados. A categoria de desocupados leva em conta pessoas com 14 anos ou mais de idade, que não trabalharam na semana da entrevista, mas que buscaram trabalho nos 30 dias anteriores. Não são consideradas pessoas que não trabalharam na semana de referência por já terem encontrado ocupação com início em até 4 meses após o dia da entrevista.

Os dados da metodologia atual da pesquisa estão disponíveis a partir de 2012, de tal forma, a série possui 42 observações. A restrição de observações impõe dificuldades sobre os processos de modelagem e projeção das séries, uma vez que a inserção das variáveis explicativas compromete os graus de liberdade das regressões, e, portanto, a qualidade das projeções.

As demais séries utilizadas nas estimações são variáveis macroeconômicas, que afetam de forma direta ou indireta a situação do emprego no país, são elas PIB, Selic em termos reais e Termos de Troca. A variável de PIB explica a evolução da taxa de desocupação pois expressa informações a respeito do nível de atividade da economia, fator que influencia a oferta e demanda por trabalho, a série utilizada foi a variação do índice de volume medido pelo Sistema de Contas Nacionais Trimestrais (SCNT), elaborada pelo IBGE, e, portanto, representa a variação entre o resultado de um trimestre contra mesmo período do ano anterior na série de preços constantes.

A taxa básica de juros da economia, Selic, disponibilizada pelo Banco Central do Brasil (BCB), trimestralizada e em termos reais, descontada a variação da inflação do Índice Nacional de Preços ao Consumidor Amplo (IPCA), estimado pelo IBGE, também afeta a evolução do desemprego através do seu impacto na atividade. Por fim, a variável de Termos de Troca, estimada pela Secretaria de Comércio Exterior do Ministério da Economia (SECEX), representa a razão entre o índice de preços das exportações e o das importações em número índice. A série da taxa de câmbio, em termos reais, também foi testada, entretanto, a série de Termos de Troca apresentou melhor desempenho explicativo em conjunto com as demais variáveis, e por isso foi mantida.

Os Termos de Troca expressam a relação entre os níveis necessários de transações internacionais, entre exportações e importações, para que se mantenha uma equivalência na

balança comercial. Ou seja, um aumento nos termos de troca indica um aumento relativo do retorno das exportações, de forma que o nível de importações, mantido constante, equivale à uma redução no nível de exportações necessárias para a manutenção dessa equivalência. A série, portanto, agrega informações a respeito da evolução do câmbio, comércio internacional e formação de preços, expressando o impacto dessas variáveis no mercado de trabalho.

3.2. Tratamento dos dados

Com exceção do método de Holt-Winters, a realização das projeções é feita a partir do pressuposto de que é possível estimar o valor de uma variável em um determinado momento do tempo se conhecermos os valores já realizados da série, desde que as séries apresentem convergência. Nesses casos, é imprescindível que as séries apresentem padrão de estacionariedade, a fim de proporcionar não apenas as condições necessárias para a estabilidade e convergência dos modelos, mas também como forma de evitar a introdução de viés na estimação e a incorrência em relações espúrias.

Três dos testes realizados não consideram a especificação ou o controle de padrões de sazonalidade ou de quebras estruturais nas séries, são eles: Dickey-Fuller Aumentado (ADF), Phillips-Perron (PP) e Kwiatkowski-Phillips-Schmidt-Shin (KPSS). Dois dos testes utilizados são elaborados de forma específica para séries que apresentam padrão de sazonalidade, os testes Hylleberg-Engle-Granger-Yoo (HEGY) e Canova-Hansen (CH). Por fim, foi também utilizado o teste de raiz unitária para série com quebra estrutural, proposto por Perron.

Os Testes ADF e PP operam de forma semelhante, ambos são realizados a partir da elaboração e resolução de uma equação em diferenças da série analisada, e avaliam a probabilidade do coeficiente relacionado à defasagem da própria série admitir, de forma estrita, soluções maiores que um, portanto, testam a hipótese nula de presença de raiz unitária nas séries. A equação do teste ADF é dada por:

$$\Delta y_t = \alpha + \beta T + \gamma y_{t-1} + \sum_{i=1}^p \delta_i z_{t-i} + \varepsilon_t$$

A equação estimada pelo teste PP é dada por:

$$y_t = \alpha + \beta T + \rho y_{t-1} + \varepsilon_t$$

O teste KPSS assume o comportamento estacionário, ou estacionário em torno de uma tendência, como hipótese nula. O teste é realizado, portanto, sobre a probabilidade de a variância da série assumir valor igual a 0, mesmo que essa variância seja 0 em torno de uma média. Ou seja, o resultado do teste KPSS, mesmo em casos que não seja possível rejeitar a hipótese nula de estacionariedade, não garante a ausência de raiz unitária nas séries. O teste considera o modelo $y_t = \alpha + \beta T + \delta_{t-1} + \varepsilon_t$, em que δ assume comportamento de passeio aleatório. A estatística LM do teste é dada por:

$$LM = \frac{\sum_{t=1}^T S_t^2}{\sigma_\varepsilon^2}$$

Onde S_t^2 representa a soma dos resíduos da equação estimada.

O teste HEGY é similar aos testes ADF e PP, e testa a hipótese nula de presença de raiz unitária sazonal na série analisada. O procedimento estima um polinômio autorregressivo composto por diferentes coeficientes, correspondentes às frequências da série, e testa, isoladamente, a presença de raízes unitárias nas diferentes frequências. O teste Canova-Hansen testa a hipótese nula de estacionariedade no padrão sazonal da série, operando de forma muito semelhante ao KPSS.

O teste de raiz unitária com quebra estrutural de Perron realiza uma extensão do teste ADF, permitindo que a série apresente uma mudança no intercepto ou na tendência, através da adição de outliers aditivos ou de inovação. Os outlier de inovação são utilizados quando a quebra ocorre de forma mais gradual, já os aditivos, para séries em que a quebra acontece de forma mais abrupta.

A série da Taxa de Desocupação apresenta padrão bastante irregular, com mudanças de intercepto e tendência, fatores que sugerem a presença de quebra estrutural. O componente sazonal é presente na série, apesar de não demonstrar muita força, dado que seu comportamento acaba sendo mascarado por outros componentes em diferentes momentos da série. Em nível, a série apresenta raiz unitária e não segue um padrão de estacionariedade, apesar disso, não apresenta raiz unitária sazonal. Considerando a presença de uma quebra estrutural de tendência no quarto trimestre de 2020, a série pode ser considerada estacionária, entretanto, a modelagem desse tipo de quebra pode não ser trivial. Apesar da identificação do período de quebra pelo teste de raiz unitária, a introdução de variáveis explícitas de tendência podem forçar a aderência do modelo aos dados realizados ao custo da distorção das projeções, portanto, foram também

testadas transformações da série. Em primeira diferença, a série não apresenta raiz unitária regular ou sazonal, e apresenta comportamento estacionário.

Em nível, a série de PIB apresenta raiz unitária, entretanto, não é possível rejeitar a hipótese nula de estacionariedade pelo teste KPSS. A série apresenta uma evolução bem-comportada, com alguns distúrbios, em torno de uma tendência, ou seja, apresenta um comportamento estacionário em torno de uma tendência. A remoção do componente de tendência remove também a presença de raiz unitária. Os mesmos resultados foram obtidos para os testes na variável de Selic real e, de forma semelhante, a remoção da tendência acarreta também na remoção de raízes unitárias na série.

A série dos Termos de Troca apresenta raiz unitária e comportamento não-estacionário, portanto, assume comportamento “difference stationary”, o que indica que a diferenciação da série é necessária para que ela alcance um comportamento estacionário. Com uma diferenciação simples a série apresenta tanto padrão estacionário quanto ausência de raiz unitária. Os resultados dos testes podem ser visualizados nas Tabelas A1 e A2 do apêndice.

4. Modelos

Os parâmetros utilizados para avaliação dos modelos foram o erro padrão, soma do quadrado dos resíduos e os critérios de informação de Akaike, Schwarz e Hannan-Quinn. Os critérios de informação são utilizados como parâmetros de seleção dos modelos uma vez que geram uma medida de qualidade da estimação levando em conta o critério de parcimônia, de tal forma, ponderam os benefícios e prejuízos advindos da inclusão de cada um dos regressores da equação.

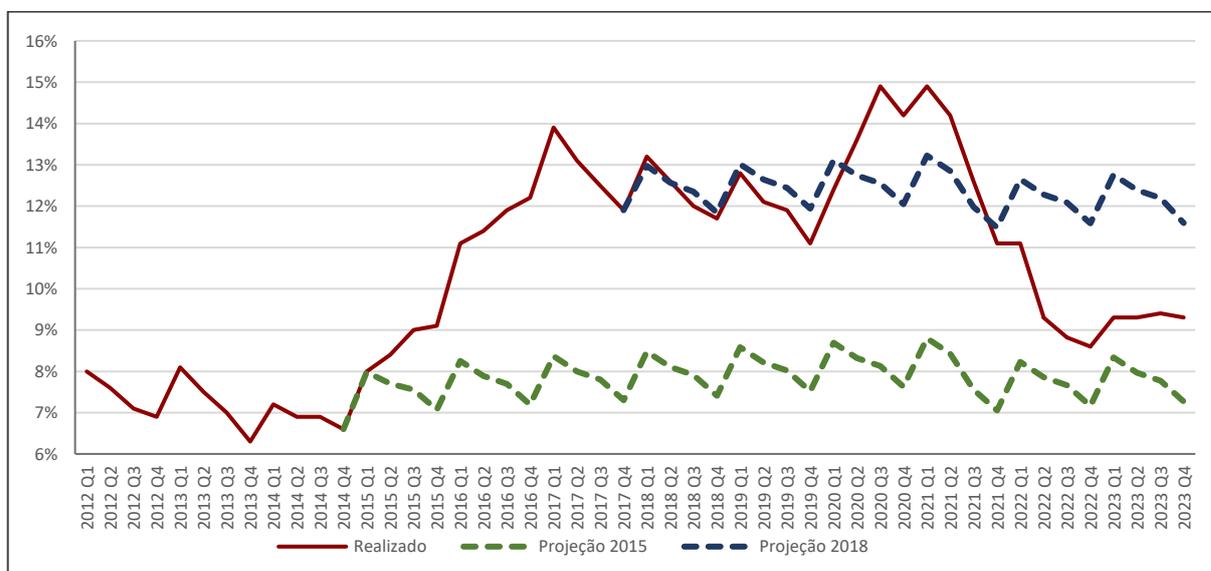
4.1. ARIMA

O modelo ARIMA proposto para a taxa de desocupação foi estimado com uma diferenciação de ordem um e conta com a presença de um intercepto e dummies de controle sazonal como componentes determinísticos. Quanto às defasagens da própria série, a estrutura do correlograma da série indica a presença de um processo de médias móveis, dada a correlação sinalizada em um intervalo de 4 períodos, equivalente a frequência da série. O correlograma da série pode ser visualizado na Figura A1 do apêndice.

A adição de um componente autorregressivo de ordem um também contribuiu com o desempenho do modelo e das projeções, e com a redução dos critérios de informação. O modelo também conta com uma dummy exógena que sinaliza o terceiro trimestre de 2021, período de choque da COVID-19 na série diferenciada. De tal forma, o modelo selecionado foi o ARIMA (1,1,1) com intercepto, dummies sazonais, e uma dummy para a COVID-19,

Os modelos ARIMA, por utilizarem majoritariamente o padrão do comportamento passado da série para estimar os valores futuros, não são capazes de gerar autonomamente mudanças no nível da série, dado que estas são causadas por choques exógenos, que não podem ser explicados pela equação estimada, conforme pode ser visualizado no Gráfico 2. Os parâmetros estimados pela regressão podem ser visualizados na Figura A2 do apêndice.

GRÁFICO 2 – Evolução da Taxa de Desocupação e de projeções do modelo ARIMA (%)



Esse fator pode prejudicar o desempenho das projeções ARIMA em casos como o da taxa de desocupação, que apresenta acomodações em diferentes níveis ao longo tempo. Conforme mencionado, o controle dessas mudanças pode ser feito através da introdução de dummies, que sinalizam os períodos de comportamentos atípicos, entretanto, vale ressaltar que a adição desses componentes deve ser realizada com parcimônia, uma vez que podem produzir um processo de aderência artificial nos modelos, mascarando o real comportamento da série e deteriorando a qualidade das projeções.

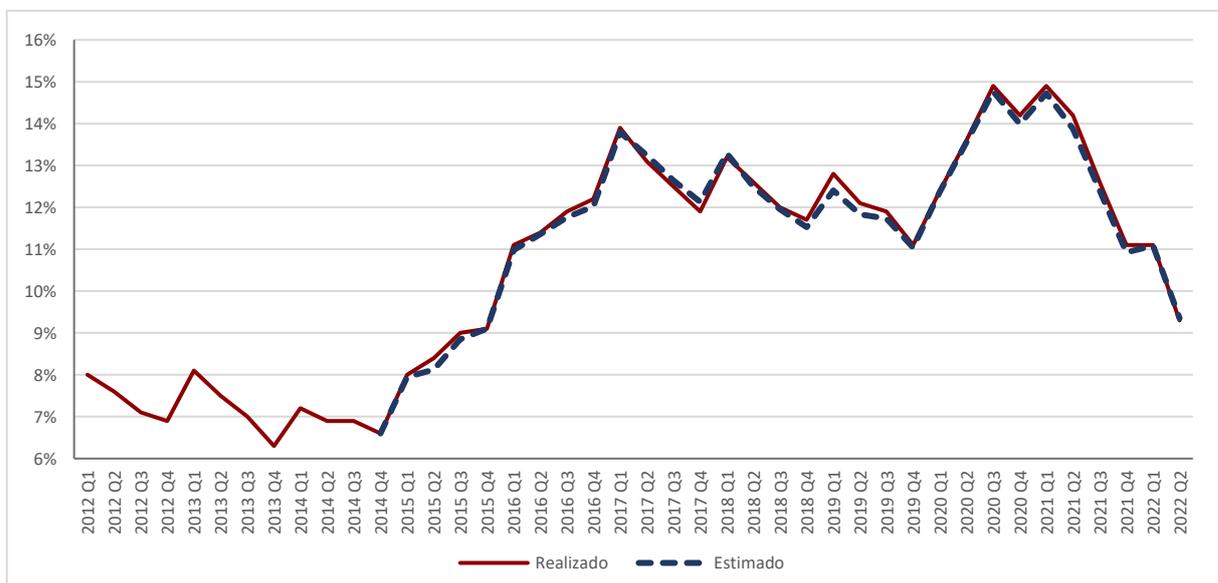
4.2. ARDL

Para a categoria de modelos ARDL, o modelo conta com a presença de um intercepto, dummies trimestrais, quatro defasagens da própria série, as variáveis de PIB e Selic real, com três defasagens cada, e a variável de Termos de Troca, com uma defasagem. Foram testadas composições alternativas, com o intuito de reduzir o número de regressores do modelo, entretanto, estratégias como a redução do número de defasagens ou exclusão de algumas das variáveis não apresentaram bons resultados.

As variáveis explicativas estimadas dos modelos podem tanto apresentar impactos contínuos, como é o caso do PIB, em que suas defasagens afetam o PIB de forma estatisticamente significativa por até quatro períodos, considerando o valor contemporâneo, quanto um impacto tardio, como é o caso da Selic, em que as defasagens apresentam cada vez maior significância quanto mais distantes do período estimado, com pico de significância na terceira defasagem. A remoção dessas defasagens significativas acaba, então, distorcendo o impacto das variáveis exógenas no modelo, de forma que afeta o desempenho tanto das projeções quanto dos valores estimados dentro da amostra.

Apesar do número elevado de regressores, o modelo minimizou os critérios de informação e apresentou o melhor desempenho de estimação e projeção da série dentre os estimados pela mesma metodologia e, portanto, foi mantido. Os parâmetros da regressão podem ser visualizados na Figura A3 do apêndice.

GRÁFICO 3 – Evolução da Taxa de Desocupação e da estimação do modelo ARDL (%)



Conforme explicitado no segundo capítulo, os modelos ARDL usualmente apresentam alto poder explicativo, o que resulta em uma boa aderência entre série estimada e série realizada, entretanto, as projeções realizadas pelo método, para períodos ainda não realizados, exigem a disponibilização dos valores futuros das variáveis explicativas, pois, uma vez que afetam o modelo de forma exógena, não podem ser estimados internamente. Portanto, para a realização das projeções a partir do 3º trimestre de 2022, foi adotada a hipótese de convergência à média histórica para as séries de PIB e Termos de Troca. A série de Selic real foi estimada a partir dos valores esperados para a taxa Selic e IPCA do Sistema Expectativas de Mercado, do Banco Central.

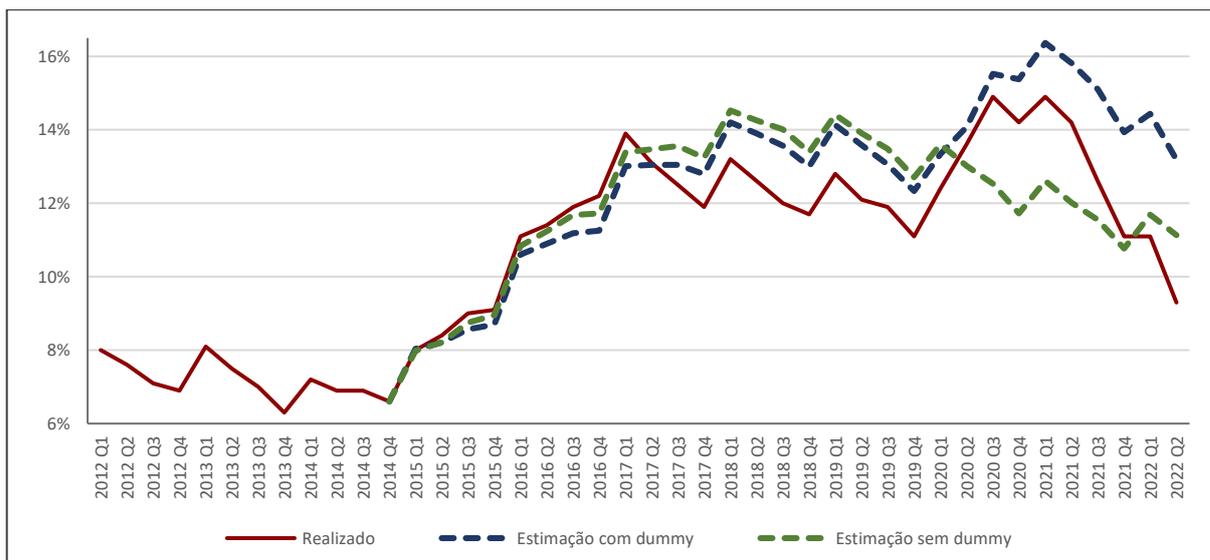
4.3. VAR

Os primeiros direcionamentos a respeito da composição dos modelos VAR foram obtidos a partir da estimação da correlação simples e da causalidade de Granger entre as variáveis. Segundo a tabela de correlação simples, a taxa de desocupação apresenta maior correlação com as variáveis de PIB e Câmbio. Segundo os resultados do teste de Granger, rejeitamos a hipótese nula de não causalidade do PIB na Taxa de Desocupação. Também foi identificada a relação de causalidade de Granger dos Termos de Troca na Taxa de Desocupação. Não foi possível estabelecer relação de causalidade de Granger de outras variáveis no PIB ou uma relação de causalidade da Selic em outras variáveis. Os resultados do teste de Granger podem ser verificados na Tabela A3 do apêndice.

O modelo proposto conta com a relação endógena entre Selic Real, PIB e Taxa de Desocupação, com três defasagens. Como variáveis exógenas foram inseridos um intercepto, dummies de controle sazonal e uma dummy, que representa o choque da COVID-19 no segundo trimestre de 2020. Os parâmetros podem ser verificados na Figura A4 do apêndice.

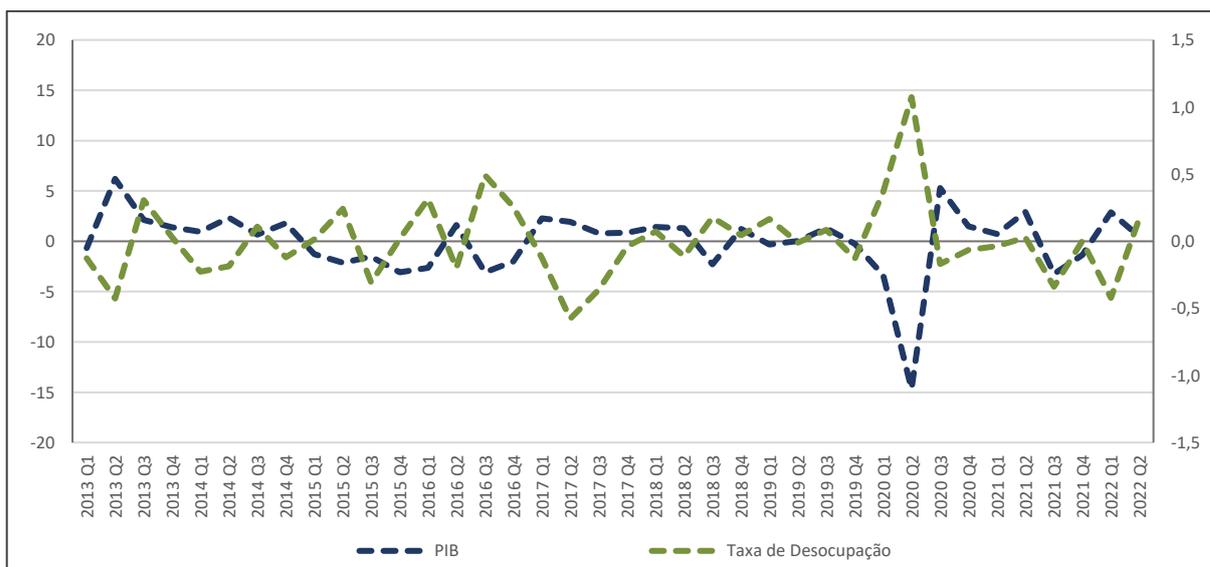
O modelo estima a relação entre as variáveis de forma endógena, enquanto o choque da COVID-19 afeta as variáveis de forma exógena, portanto, na ausência da dummy de identificação do período atípico, o modelo converge para a trajetória realizada da série, entretanto, a partir de 2017, superestima a série em momentos que não são dominados pelo choque da COVID.

GRÁFICO 4 - Evolução da Taxa de Desocupação e de estimações do modelo VAR (%)



O resultado indica que a regressão estimada consegue identificar a acomodação da série em um nível mais elevado, porém não identifica a trajetória do choque. Na ausência da dummy, o modelo também apresenta um grande distúrbio nos resíduos no período do início da pandemia no Brasil, conforme demonstrado no Gráfico 5.

GRÁFICO 5 - Resíduos do modelo VAR



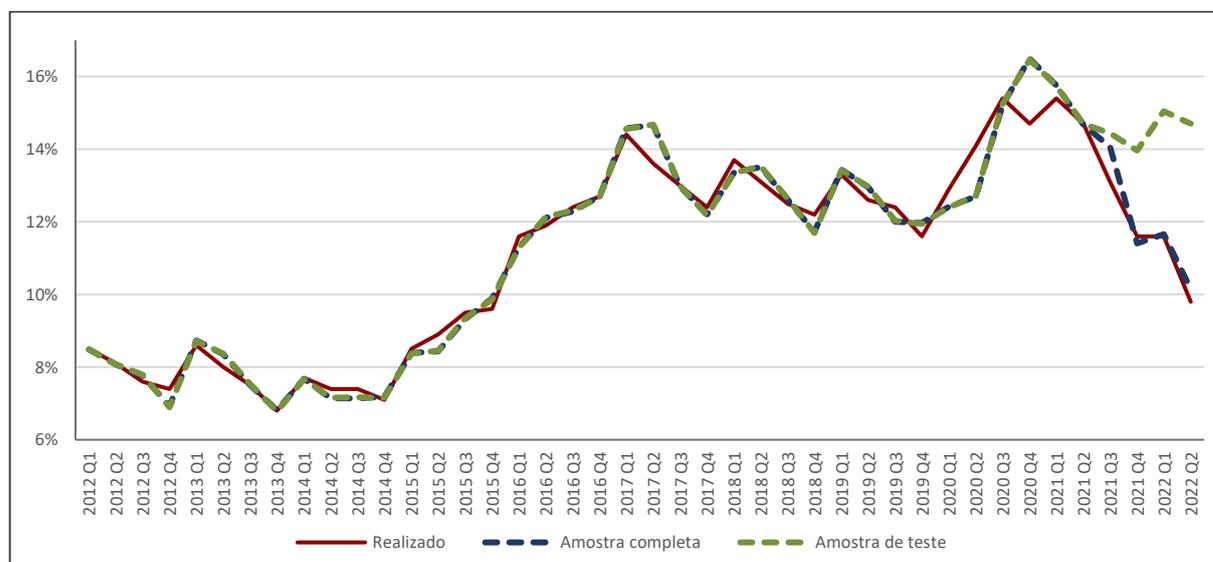
4.4. Holt-Winters

Como já mencionado, a realização da projeção de séries pelo método de Holt Winters parte da estimação dos componentes de ciclo, tendência e sazonalidade, que podem assumir caráter aditivo ou multiplicativo, e da determinação do peso dos componentes em relação ao

tempo, determinados, respectivamente pelos parâmetros α , β e γ . Os parâmetros que proporcionaram a redução dos critérios de informação e dos erros de previsão do modelo foram de 1 para α , 0,9 para β , e 0 para γ . Os parâmetros podem ser verificados na Figura A5 do apêndice.

A projeção por suavização exponencial utiliza apenas as informações passadas da própria série como insumos para a composição de seus valores futuros, portanto, o desempenho das estimações fora da amostra é altamente afetado pelas informações da ponta, de tal forma, a série estimada fora da amostra pode apresentar trajetórias diversas a depender da janela utilizada pela estimação, de forma que o recuo da taxa de desocupação nos últimos trimestres só passa a ser incorporado com a adição das observações que indicam os primeiros sinais de queda.

GRÁFICO 6 - Evolução da Taxa de Desocupação e da estimação do modelo Holt-Winters (%)



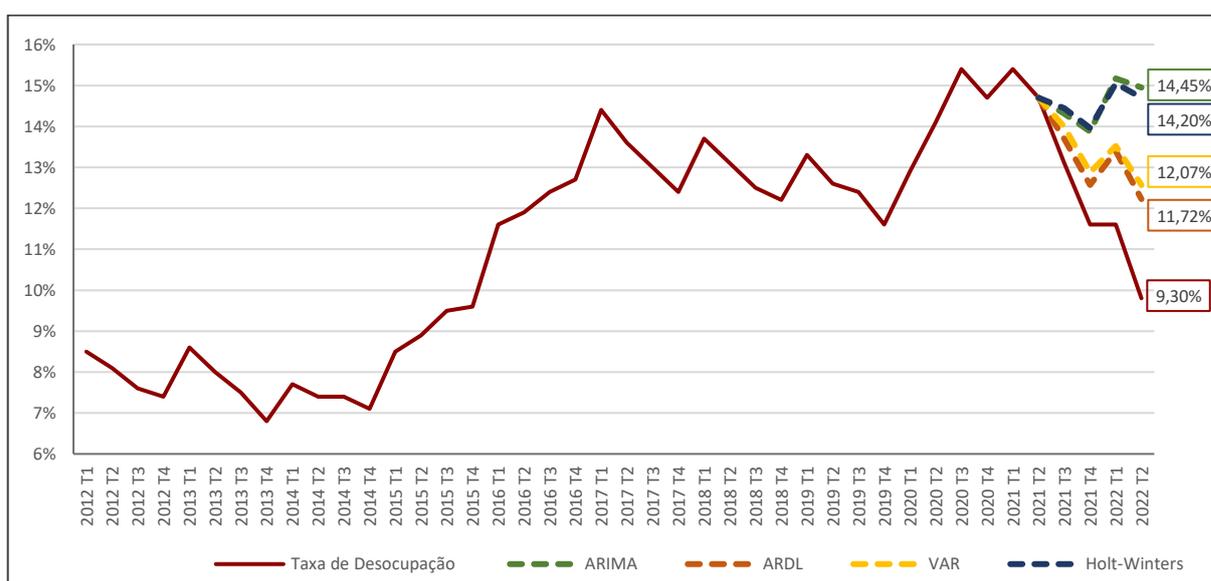
5. Comparação entre os resultados

Com a finalidade de análise do desempenho dos modelos propostos, foram comparados os resultados das projeções realizados com base em uma amostra de treino, que possibilita a comparação dos resultados com valores já realizados das séries, e de projeções realizadas com uma amostra completa, tendo seus resultados comparados com os valores esperados para a Taxa de Desocupação, gerados pelo sistema de Expectativas de Mercado do Banco Central do Brasil.

5.1. Amostra de treino

A amostra de treino abarca o período entre o 1º trimestre de 2012 e o 2º trimestre de 2021, com extensão das projeções até o 2º trimestre de 2022. Considerando as janelas de estimação e projeção, o melhor desempenho foi o obtido pelo modelo ARDL. A comparação entre os resultados pode ser vista no Gráfico 7.

GRÁFICO 7 - Evolução da Taxa de Desocupação e projeções de teste (%)



Vale ressaltar a similaridade do desempenho entre as projeções considerando o tipo de informação que cada método utiliza. Os modelos ARDL e VAR, que levam em conta o impacto de outras variáveis no processo gerador de dados, apresentam resultados semelhantes entre si, e mais próximos dos valores realizados da série em comparação com os métodos ARIMA e Holt-Winters. Apesar dos resultados ainda superestimados, a influência das demais variáveis gera uma sinalização da redução do nível da desocupação, permitindo algum nível de identificação da alteração do patamar da série.

Os métodos que utilizam apenas informações passadas da própria série na estimação dos valores futuros, ARIMA e Holt-Winters, também apresentam resultados muito semelhantes, porém com maior distanciamento entre as séries estimadas e a realizada. A determinação dos valores pautada exclusivamente no comportamento passado da série acarreta a impossibilidade de identificação do movimento de recuo da desocupação a partir do 2º semestre de 2021, de forma que os dados projetados replicam a movimentação padrão da série para os períodos futuros, com uma acomodação na faixa entre os 13% e 15%.

Em decorrência desses fatores, as projeções realizadas por um mesmo modelo ARIMA ou Holt-Winters, com diferentes janelas de estimação, apresentam resultados mais distintos em relação aos modelos que consideram também a inserção de outras variáveis explicativas, dado que as informações da ponta geram grande influência no comportamento adotado nos valores estimados fora da amostra. Abaixo, a Tabela 1 apresenta os erros de estimação de cada modelo.

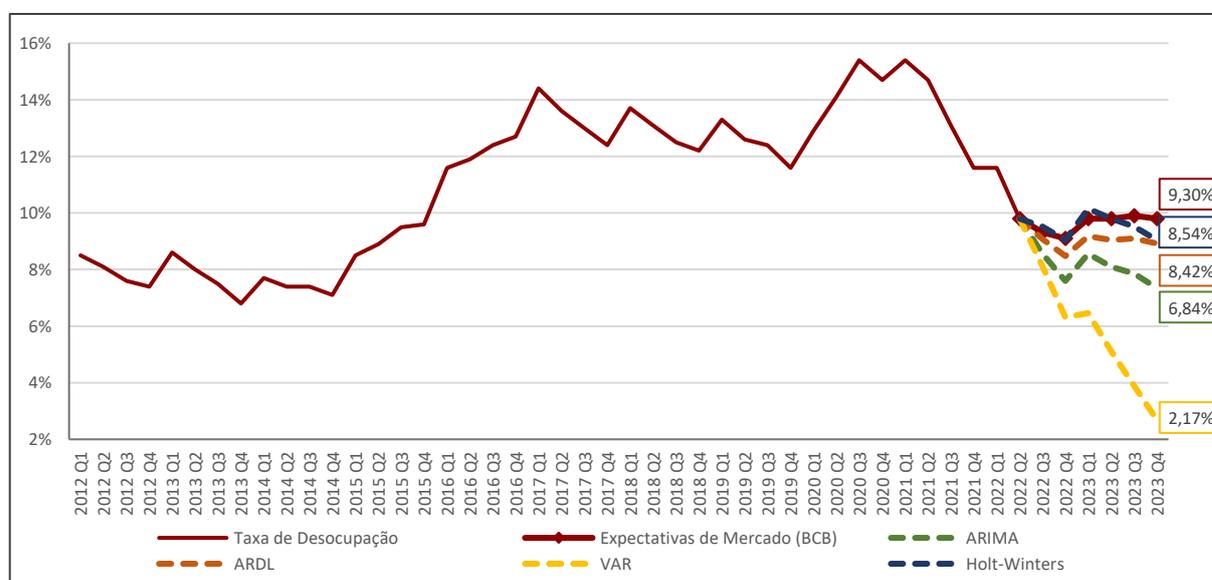
TABELA 1 - Medidas de erro das projeções

Projeções	RMSE	MAE	MAPE	SMAPE
ARIMA	3,39	3,05	29,40	24,70
ARDL	1,61	1,45	13,93	0,07
VAR	1,85	1,71	16,40	0,08
Holt-Winters	3,29	3,01	28,92	24,48

5.2. Amostra completa

A estimação com amostra completa, que conta com todos os dados realizados disponíveis para as séries abarca o período entre o 1º trimestre de 2012 e o 2º trimestre de 2022, com extensão das projeções até o 4º trimestre de 2023. A estimação pelo método de Holt-Winters é a que mais se aproxima da Taxa de Desocupação do Sistema de Expectativas de Mercado.

GRÁFICO 8 - Evolução da Taxa de Desocupação e projeções (%)



O método de projeção de Holt-Winters, conforme explicitado, opera como um sistema de médias ponderadas dos valores passados da série, portanto, não gera autonomamente grandes

alterações no nível da série, mas sim movimentos de acomodação em nível. Por um ponto de vista metodológico, a Taxa de Desocupação do Sistema de Expectativas de Mercado também apresenta resultado mais suavizado, uma vez que é estimada através da mediana de projeções de diferentes instituições, disponibilizadas até 30 dias antes da data de estimação, tal fator corrobora com a aproximação entre as séries.

Os valores projetados pelo modelo ARIMA apresentam trajetória semelhante à estimada pelo método de Holt-Winters, porém com acomodação em um nível inferior. Tal fator pode ser explicado pela presença do componente de médias móveis no modelo, que pode prolongar o tempo de dissipação de mudanças no regime da série, ou seja, prolonga a tendência de queda presente nas últimas observações incluídas no modelo, gerando uma maior redução no nível da série.

A série final projetada pelo modelo ARDL, estimada com base na hipótese de conversão à média para as variáveis exógenas, apresenta resultado intermediário entre as projeções de Holt-Winters e ARIMA. Conforme abordado anteriormente, a escolha dos valores futuros das variáveis exógenas determina a resposta das projeções, de tal forma, a hipótese de convergência das variáveis explicativas influencia a estabilidade da projeção.

A série estimada pelo VAR apresenta os resultados mais distantes, tanto das Expectativas de Mercado quanto das demais projeções. O valor estimado para o último trimestre de 2023, de 2,7%, se encontram 3,6 pontos percentuais abaixo da mínima histórica da série, de 6,3%. O modelo conta com boa capacidade explicativa dentro da amostra, entretanto, não identifica autonomamente o choque da COVID-19, tornando necessária a adição de uma dummy para o período. A presença da dummy contribui de forma positiva com o desempenho geral do modelo, porém acentua a tendência de queda no fim da série modelada.

A manutenção dessa tendência ao longo do tempo pode indicar uma dificuldade de dissipação do choque no modelo. Outros fatores que podem explicar o resultado, são os valores projetados de forma endógena pelo modelo. A amostra completa utilizada na estimação dos modelos se encerra no 2º trimestre de 2022, último período comum entre as séries. Apesar disso, para algumas séries, os dados do 3º trimestre já se encontram disponíveis, como é o caso da Selic real. No período em questão, a taxa de variação apresenta elevado crescimento, entretanto, a projeção não consegue prever essa oscilação, a má identificação de uma alta na Selic, fator que gera incentivos de retração de atividade, em conjunto com a alta do PIB em 2023, estimada

endogenamente pelo modelo, pode justificar a posição de otimismo estimada até o final de 2023.

TABELA 2 – Medidas de erro das projeções

Projeções	RMSE	MAE	MAPE	SMAPE
ARIMA	1,71	1,62	17,64	19,56
ARDL	0,68	0,65	7,12	7,41
VAR	4,64	4,19	45,51	63,81
Holt-Winters	0,38	0,29	3,15	3,20

6. Conclusão

As metodologias de projeção apresentam diferentes vantagens, os modelos multivariados proporcionam maior poder explicativo da amostra realizada, dada a identificação de variáveis explicativas e seus respectivos impactos no sistema, entretanto, esse alto poder explicativo pode não se traduzir em alto poder preditivo.

Os modelos univariados proporcionam maior simplicidade, uma vez que a elaboração das estimações não depende de variáveis explicativas, de forma que reduz os problemas de hiper parametrização e má identificação dos modelos, dado que propõe a identificação do comportamento passado da série, e não a identificação de um sistema propriamente dito.

Para o caso da Taxa de Desocupação brasileira, as projeções dos modelos multivariados apresentam melhor poder explicativo nas amostras de teste. Considerando a amostra completa dos dados realizados e as projeções para o período entre o 3º trimestre de 2022 e último trimestre de 2023, o desempenho da projeção ARDL é altamente afetado pelos valores futuros assumidos pelas variáveis exógenas, portanto, não depende apenas dos parâmetros estimados pelo modelo.

O modelo VAR, apesar de apresentar a possibilidade de determinação da relação endógena das variáveis, o que amplia a capacidade explicativa dos modelos, pode gerar distorções nas projeções, uma vez que a má identificação dessas relações internas acarreta o desvio da trajetória das séries do modelo em conjunto. Portanto, para que o modelo VAR possa realizar boas projeções, é necessário que os coeficientes do modelo estejam muito bem calibrados, a fim de proporcionar a dissipação dos choques de forma adequada, fator que se torna especialmente sensível em amostras pequenas de dados, dado que limita a inserção de variáveis explicativas. No modelo estimado, tanto a decomposição de variância quanto a função impulso resposta apresentam as relações entre as variáveis endógenas conforme o esperado

teoricamente, entretanto, no longo prazo não identifica corretamente a dissipação do choque e acomodação da série.

As projeções dos modelos ARIMA e Holt-Winters apresentam grandes desvios em relação à série realizada, no caso dos modelos estimados com amostra de teste, isso porque não geram alterações no nível da série, já no caso das projeções realizadas com amostra completa dos dados, apresentam resultados similares ao do modelo ARDL e da série das Expectativas de Mercado do Banco Central do Brasil. Conforme elucidado, as projeções pelo método são altamente afetadas pelo comportamento dos dados da ponta, ou seja, os dados mais recentes incluídos nas séries.

Portanto, o desempenho obtido por cada modelo não depende apenas do método utilizado, mas das especificidades da série que se deseja estimar, e de como esses fatores são identificados por cada um dos métodos.

7. Referências

POLLOCK, David S. G. Introduction to the Special Issue on Statistical Extraction and Filtering. *Computational Statistics & Data Analysis*, Vol. 50, p. 2137 - 2145. Maio, 2006.

ENDERS, Walter. *Applied Econometric Time Series*. 4 ed. EUA: Willey, 2015.

BOX, George E. P.; JENKINS Gwilym M. *Time Series Analysis: Forecasting and Control*. 1 ed. Local: Editora, 1970.

LIMA, Susana; GONÇALVES, A. Manuela; COSTA, Marco. *Time Series Forecasting using Holt Winters Exponential Smoothing: An Application to Economic Data*. Proceedings of the International Conference of Computational Methods in Sciences and Engineering. Portugal, 2019.

BOHN, Liana. *Os Cisnes Cinzentos do Desemprego no Brasil: A Previsão a Partir de Padrões Regulares*. Dissertação (Mestrado em Ciências Econômicas) – Departamento de Economia, Universidade Federal de Viçosa. Viçosa, 2013.

LENZA, Michele; PRIMICERI, Giorgio E. *How to Estimate a VAR After March 2020*. National Bureau of Economic Research. Cambridge, Massachusetts, 2020. (<https://www.nber.org/papers/w27771>)

GOSTKOWSKI, Michael; ROKICKI, Tomasz. *Forecasting the Unemployment Rate: Application of Selected Prediction Methods*. *European Research Studies Journal*, Volume XXIV, Issue 3. 2021.

Apêndice

TABELA A1 – Resultados dos testes ADF e PP

Séries de dados	Transformação	ADF (p-valor)	PP (p-valor)
Taxa de Desocupação	Diferenciação de ordem 1	0,0201	0,0000
PIB	Remoção de tendência	0,0169	0,0221
Selic real	Remoção de tendência	0,0000	0,0000
Termos de Troca	Diferenciação de ordem 1	0,0000	0,0000

TABELA A2 – Resultados dos testes KPSS

Séries de dados	Transformação	KPSS (Estatística LM*)
Taxa de Desocupação	Diferenciação de ordem 1	0,2477
PIB	Remoção de tendência	0,1386
Selic real	Remoção de tendência	0,1207
Termos de Troca	Diferenciação de ordem 1	0,0895

*Valores críticos do teste KPSS: 10%: 0,347; 5%: 0,463; 1%: 0,739.

FIGURA A1 – Correlograma da Taxa de Desocupação com diferenciação de ordem 1

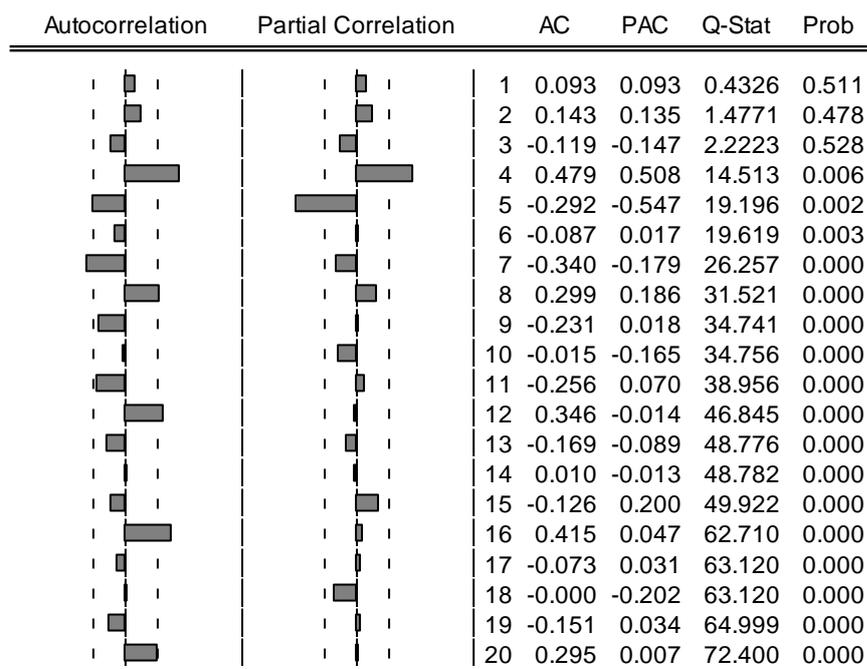


TABELA A3 - Resultados dos testes de causalidade de Granger

Hipótese nula	p-valor
PIB não Granger causa Taxa de Desocupação	0,0047
Taxa de Desocupação não Granger causa PIB	0,9524
Selic real não Granger causa Taxa de Desocupação	0,1129
Taxa de Desocupação não Granger causa Selic real	0,9149
Termos de Troca não Granger causa Taxa de Desocupação	0,0029
Taxa de Desocupação não Granger causa Termos de Troca	0,4993
Câmbio real não Granger causa Taxa de Desocupação	0,1180
Taxa de Desocupação não Granger causa Câmbio real	0,7498

FIGURA A2 – Parâmetros do modelo ARIMA

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.173832	0.245407	4.783200	0.0000
B_21Q3	-0.679374	0.251452	-2.701808	0.0108
@QUARTER=2	-1.543410	0.141747	-10.88845	0.0000
@QUARTER=3	-1.367409	0.227393	-6.013407	0.0000
@QUARTER=4	-1.676510	0.191040	-8.775720	0.0000
AR(1)	0.447219	0.190001	2.353777	0.0247
MA(1)	0.677642	0.200499	3.379774	0.0019
SIGMASQ	0.155501	0.047249	3.291063	0.0024
R-squared	0.814280	Mean dependent var		0.031707
Adjusted R-squared	0.774885	S.D. dependent var		0.926401
S.E. of regression	0.439543	Akaike info criterion		1.400364
Sum squared resid	6.375531	Schwarz criterion		1.734720
Log likelihood	-20.70747	Hannan-Quinn criter.		1.522118
F-statistic	20.66959	Durbin-Watson stat		1.953020
Prob(F-statistic)	0.000000			

FIGURA A3 – Parâmetros do modelo ARDL

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.583729	0.181350	8.732987	0.0000
D(TX_DESOCUP(-1))	0.274157	0.181002	1.514667	0.1463
D(TX_DESOCUP(-2))	0.045147	0.147796	0.305471	0.7633
D(TX_DESOCUP(-3))	0.316511	0.131911	2.399430	0.0268
D(TX_DESOCUP(-4))	-0.297303	0.099362	-2.992134	0.0075
PIB_TESTE	-0.064176	0.010959	-5.856004	0.0000
PIB_TESTE(-1)	-0.060779	0.017730	-3.428076	0.0028
PIB_TESTE(-2)	0.083213	0.013589	6.123518	0.0000
PIB_TESTE(-3)	0.064936	0.020487	3.169597	0.0050
SELIC_REAL_DT	0.058750	0.053103	1.106342	0.2824
SELIC_REAL_DT(-1)	-0.004072	0.067104	-0.060688	0.9522
SELIC_REAL_DT(-2)	-0.046631	0.065501	-0.711906	0.4852
SELIC_REAL_DT(-3)	0.164438	0.058368	2.817240	0.0110
TERMOS_TROCA_D	0.024633	0.012380	1.989757	0.0612
TERMOS_TROCA_D(-1)	0.031450	0.011830	2.658641	0.0155
@QUARTER=2	-2.805418	0.339492	-8.263565	0.0000
@QUARTER=3	-1.440386	0.280028	-5.143720	0.0001
@QUARTER=4	-1.991741	0.378001	-5.269137	0.0000
R-squared	0.976881	Mean dependent var		0.032432
Adjusted R-squared	0.956195	S.D. dependent var		0.949285
S.E. of regression	0.198681	Akaike info criterion		-0.087739
Sum squared resid	0.750008	Schwarz criterion		0.695951
Log likelihood	19.62317	Hannan-Quinn criter.		0.188548
F-statistic	47.22540	Durbin-Watson stat		2.203654
Prob(F-statistic)	0.000000			

FIGURA A4 – Parâmetros do modelo VAR

	SELIC_REA...	PIB_DT	D(TX_DES...
SELIC_REAL_DT(-1)	0.733440 (0.21511) [3.40960]	-0.962938 (1.06553) [-0.90371]	0.101992 (0.09508) [1.07269]
SELIC_REAL_DT(-2)	-0.282211 (0.24654) [-1.14469]	1.058672 (1.22121) [0.86690]	-0.204266 (0.10897) [-1.87447]
SELIC_REAL_DT(-3)	0.355411 (0.19588) [1.81441]	-1.021516 (0.97029) [-1.05279]	0.302241 (0.08658) [3.49079]
PIB_DT(-1)	-0.056712 (0.05270) [-1.07621]	0.798548 (0.26103) [3.05926]	-0.089906 (0.02329) [-3.85990]
PIB_DT(-2)	0.028438 (0.05345) [0.53202]	0.113112 (0.26477) [0.42720]	0.074011 (0.02363) [3.13253]
PIB_DT(-3)	0.049250 (0.06231) [0.79038]	-0.138992 (0.30866) [-0.45031]	0.045265 (0.02754) [1.64346]
D(TX_DESOCUP(-1))	-0.959703 (0.51555) [-1.86151]	0.835359 (2.55374) [0.32711]	0.335722 (0.22788) [1.47325]
D(TX_DESOCUP(-2))	0.708432 (0.51674) [1.37097]	0.632999 (2.55963) [0.24730]	0.201767 (0.22840) [0.88338]
D(TX_DESOCUP(-3))	0.034716 (0.40820) [0.08505]	-1.664454 (2.02198) [-0.82318]	0.165167 (0.18043) [0.91542]
C	-0.423989 (0.35554) [-1.19252]	-3.963775 (1.76114) [-2.25069]	1.400818 (0.15715) [8.91376]
@QUARTER=2	2.022286 (0.81617) [2.47776]	3.292169 (4.04286) [0.81432]	-2.518624 (0.36076) [-6.98148]
@QUARTER=3	-0.504228 (1.04713) [-0.48153]	6.938240 (5.18687) [1.33765]	-1.728498 (0.46284) [-3.73453]
@QUARTER=4	0.282356 (0.85362) [0.33078]	4.290680 (4.22834) [1.01474]	-1.431947 (0.37731) [-3.79517]
R-squared	0.553746	0.727108	0.904309
Adj. R-squared	0.339545	0.596120	0.858377
Sum sq. resids	16.53926	405.8157	3.231340
S.E. equation	0.813370	4.028974	0.359519
F-statistic	2.585162	5.550945	19.68809
Log likelihood	-38.11453	-98.91761	-7.090571
Akaike AIC	2.690238	5.890401	1.057398
Schwarz SC	3.250465	6.450627	1.617625
Mean dependent	0.009428	-1.777175	0.063158
S.D. dependent	1.000844	6.339692	0.955332
Determinant resid covariance (dof adj.)		0.570415	
Determinant resid covariance		0.162428	
Log likelihood		-127.2261	
Akaike information criterion		8.748741	
Schwarz criterion		10.42942	
Number of coefficients		39	

FIGURA A5 – Parâmetros do modelo Holt-Winters

Parameters	
Alpha (fixed):	1.000000
Beta (fixed):	0.900000
Gamma (fixed):	0.000000
Compact Log-likelihood	-40.40965
Log-likelihood	-21.51401
Akaike Information Criterion	86.81931
Schwarz Criterion	92.03232
Hannan-Quinn Criterion	88.73008
Sum of Squared Residuals	0.065390
Root Mean Squared Error	0.039458
Average Mean Squared Error	1.330524