

# Previendo a inflação no Brasil com grande conjunto de dados: uma aplicação do modelo de fatores comuns

*Cristiano Santos\**, *Roberto Tatiwa Ferreira†*, *Ivan Castelar‡*

*25 de abril de 2016*

## Resumo

Este artigo compara as previsões da inflação acumulada em 12 meses fornecidas por modelos índice de difusão que usam fatores comuns estimados de um grande conjunto de dados, com as previsões fornecidas pela pesquisa Focus do Banco Central do Brasil e por modelos autor-regressivo integrado de média móvel (ARIMA) e vetor autorregressivo (VAR). Os resultados mostram que as previsões da pesquisa Focus são as que apresentam menor erro quadrático médio entre os modelos comparados e que os ganhos de se utilizar grande quantidade de dados para prever a inflação são limitados. Apenas o modelo índice de difusão que usa pré-seleção de variáveis na estimação dos fatores comuns adiciona informações à previsão da pesquisa Focus, de forma que o erro quadrático médio da previsão combinada é menor do que o erro quadrático médio de cada previsão isoladamente.

**Palavras-chave:** Previsão. Inflação. Modelo de fatores. Grande conjunto de dados.

## Abstract

This paper compares the forecasts of inflation in 12 months provided by models diffusion index using a large data set, by Focus survey of Brazil's Central Bank, by integrated autoregressive models moving average (ARIMA) and by vector autoregression (VAR). The results show that the Focus survey forecasts are those with lower mean square error between the models compared and that the gains of using large data set to predict inflation are limited. Only diffusion index forecasts using targeted predictors add information to forecast the Focus survey, so that the mean square error of the combined forecast is lower than the mean square error of each forecast alone.

**keywords:** Forecast. Inflation. Factor Models. Large Data Sets.

**JEL Classification:** E31, E37.

**Área 4:** Macroeconomia Aplicada (Applied Macroeconomics)

---

\*Universidade Federal de Alagoas-UFAL. E-mail: cristiano1br@gmail.com

†Universidade Federal do Ceará-CAEN/UFC. E-mail: rtf2@uol.com.br

‡Universidade Federal do Ceará-CAEN/UFC. E-mail: lume1250@yahoo.com.br

# 1 Introdução

Dado que as mudanças na política monetária têm efeitos defasados sobre a economia, um dos principais objetivos ao se prever a inflação é auxiliar a autoridade monetária na definição de seus instrumentos de política no presente e no futuro próximo. No caso do Brasil, em que o Banco Central (BC) utiliza um sistema de metas, é mais relevante prever se a inflação acumulada nos próximos 12 meses estará dentro da meta do que prever a inflação em um mês específico.

Considerando a importância do problema de prever a inflação e a crescente quantidade de séries macroeconômicas disponíveis aos tomadores de decisão, este artigo prevê a inflação acumulada em 12 meses por modelos índice de difusão que usam um grande conjunto de dados e compara com as previsões fornecidas pela pesquisa Focus do BC do Brasil e por modelos autorregressivo integrado de média móvel (ARIMA) e vetor autorregressivo (VAR).

O modelo de índice de difusão (DI) proposto por Stock e Watson (2002) resume as informações contidas num grande número de séries temporais em poucos fatores comuns, que são então inseridos numa regressão simples para prever a inflação. Duas configurações diferentes deste mesmo modelo propostas por Bai e Ng (2008) e Dias et al. (2010) são também usadas neste artigo. A ideia básica é unir as metodologias do modelo Índice de Difusão com preditores e fatores *targeted*. Apesar de simples, não encontramos na literatura nenhum trabalho que utilize essa extensão do modelo DI. Assim, este artigo também contribui ao propor esse novo modelo e ao investigar sua aplicabilidade na previsão da inflação no Brasil.

Os resultados mostram que as previsões da pesquisa Focus são as que apresentam menor erro quadrático médio entre os modelos comparados, o que indica a importância da previsão da Focus para monitorar a política monetária. O desempenho dos modelos índice de difusão aponta que os ganhos de se utilizar grande quantidade de dados para prever a inflação se mostraram limitados. Apenas o modelo índice de difusão com pré-seleção de preditores de Bai e Ng (2008) adiciona informações à previsão da pesquisa Focus, de forma que o erro quadrático médio (EQM) da previsão combinada é menor do que o EQM de cada previsão isoladamente.

O trabalho está organizado da seguinte forma: A seção 2 fornece uma breve revisão da literatura. A seção 3 diz respeito ao modelo de fatores comuns e procedimento de estimação. A seção 4 descreve os modelos índice de difusão e demais modelos usados nas previsões. A seção 5 apresenta a metodologia de avaliação e os dados utilizados. A seção 6 demonstra os resultados e discussões. Por fim, a seção 7 apresenta as conclusões.

## 2 Revisão da literatura

Previsões usando fatores comuns extraídos de um grande conjunto de séries temporais ficaram conhecidas na literatura como previsão com índice de difusão, devido aos trabalhos de Stock e Watson (1998, 2002), mostrando a eficiência da metodologia. A partir de então, vários autores tem investigado a aplicação de modelos de fatores comuns para previsão das principais variáveis macroeconômicas, como a inflação e o produto, comparando com outros modelos tradicionais de previsão.

Em um trabalho extenso, Artis et al. (2005) mostram evidências que o uso dos fatores comuns na regressão de previsão melhora as previsões para as variáveis reais e de preço do Reino Unido, quando comparadas com modelos AR e VAR de séries temporais.

Usando dados da África do Sul, Gupta e Kabundi (2011) encontram que as previsões do modelo de fatores comuns para a inflação, crescimento do produto e taxa de juros, apresentam erros

menores que as previsões dos modelos VAR, VAR Bayesiano e Equilíbrio Geral Dinâmico Estocástico (DSGE). Para a Austrália, o trabalho de Moser et al. (2007) encontra que a inflação prevista com modelo de fatores supera as previsões dos modelos ARIMA e VAR em termos de eficiência preditiva.

Gavin e Kliesen (2008) utilizam modelos de fatores para prever a inflação e o produto nos Estados Unidos e descobrem que esses modelos apresentam previsões significativamente melhores que os modelos univariados. Eles ainda destacam que esses modelos são mais úteis quando o horizonte de previsão é longo. Com resultados semelhantes, Cheung e Demers (2007) indicam que o modelo índice de difusão fornece consideráveis melhorias de precisão na previsão do PIB e do núcleo da inflação do Canadá quando comparado ao modelo autorregressivo, principalmente quando o horizonte de previsão aumenta. Eles também revelam que não há diferença em termos de previsão ao usar fatores estáticos ou dinâmicos generalizados.

Schumacher e Dreger (2004) indicam que a previsão da taxa de crescimento do PIB da Alemanha com modelos de fatores comuns tem erros menores que os modelos alternativos. No entanto, essa redução não é estatisticamente significativa e concluem que o ganho de usar esse tipo de modelo na amostra por eles analisada é limitada. Com dados da área do euro, Angelini et al. (2001) reportam que não existem ganhos significativos ao usar modelos de fatores como previsor da inflação neste grupo de países.

No caso do Brasil, ainda há poucos trabalhos aplicados. Ferreira et al. (2005) usam modelos índice de difusão para prever a taxa de crescimento do PIB trimestral e encontram que esses modelos tem desempenho melhor que modelos autorregressivos. Com uma abordagem semelhante a este artigo, Figueiredo (2010) mostra que modelos de fatores podem gerar melhores previsões para a taxa de inflação brasileira, principalmente em horizontes de previsão mais longos. No entanto, Figueiredo (2010) prevê apenas a inflação mensal, enquanto neste artigo a previsão é para inflação acumulada em 12 meses utilizando novas metodologias de previsão com modelos de fatores.

Para uma revisão completa sobre modelos de fatores e previsões com índice de difusão ver o trabalho de Eickmeier e Ziegler (2008). Nele, os autores fazem uma meta-análise da grande literatura existente e descobrem que modelos de fatores possuem desempenho de previsão melhor para as variáveis dos Estados Unidos do que para Reino Unido, que o tamanho da base de dados afeta positivamente o desempenho e que pré-selecionar as variáveis incluídas na base de dados não têm influência significativa.

## 3 Modelo de Fatores Comuns

No modelo de fatores comuns, cada variável é representada como a soma de dois componentes não observados: o componente comum e o componente idiossincrático. O componente comum é formado por um pequeno número de fatores comuns que afetam todas as variáveis enquanto que o componente idiossincrático representa choques específicos a cada variável.

Dependendo da forma como os fatores comuns influenciam as variáveis, o modelo de fatores é classificado como estático, se os fatores afetam as variáveis apenas contemporaneamente, ou dinâmico, se fatores também afetam as variáveis defasadamente, ou seja, se a influência dos fatores persiste por alguns períodos.

### 3.1 Modelo de Fatores Comuns Estático

Seja  $X_t = (X_{1t}, X_{2t}, \dots, X_{Nt})'$ , para  $t = 1, \dots, T$ , um vetor  $N \times 1$  de séries temporais estacionárias com média zero. O modelo de fatores comuns supõe que cada variável  $X_{it}$  admite a seguinte representação:

$$X_{it} = \lambda_i' F_t + e_{it} \quad (1)$$

onde  $F_t$  é um vetor ( $r \times 1$ ) de fatores comuns,  $\lambda_i$  é um vetor ( $r \times 1$ ) de fatores *loadings* e  $e_{it}$  é o componente idiossincrático.

Nesse modelo há  $r$  fatores comuns  $F_t$  que sumarizam a estrutura de covariância de todas as variáveis  $X_{it}$ . A forma e a intensidade da influência de um  $F_t$  sobre uma variável específica  $i$  dependem de  $\lambda_i$ . Em outras palavras, a ideia do modelo é que a dimensão dos fatores é bem menor que a dimensão dos dados,  $r \ll N$ , de forma que um pequeno número de fatores é capaz de replicar grande parte da variância observada nas variáveis  $X_{it}$ .

Considerando a série temporal multivariada  $X_t$  de dimensão ( $N \times 1$ ), a equação (1) pode ser reescrita como:

$$X_t = \Lambda F_t + e_t \quad (2)$$

onde  $\Lambda_{(N \times r)} = (\lambda_1, \lambda_2, \dots, \lambda_r)'$  e  $e_{t(N \times 1)} = (e_{1t}, e_{2t}, \dots, e_{Nt})'$

Usando notação matricial:

$$X = F\Lambda' + e \quad (3)$$

onde  $X = (X_1, X_2, \dots, X_N)$  é uma matriz  $T \times N$  com os dados observados,  $F = (F_1, \dots, F_T)'$  é uma matriz  $T \times r$  de fatores comuns e  $e = (e_1, \dots, e_T)'$  é uma matriz  $T \times N$  de componentes idiossincráticos.

Bai e Ng (2002) e Bai (2003) mostram que os pesos (*loadings*)  $\Lambda$  dos fatores podem ser estimados pelo método de componentes principais da seguinte forma:

$$\hat{\Lambda} = \sqrt{NV} \quad (4)$$

$$\hat{F} = X\hat{\Lambda}/N \quad (5)$$

onde  $V$  é uma matriz  $N \times r$  com as colunas sendo os  $r$  maiores auto vetores da matriz  $X'X$ . A estimativa da matriz residual é obtida por  $\hat{e} = X - \hat{F}\hat{\Lambda}'$ .

É importante destacar que  $\hat{F}$  estima  $FH$  (uma rotação de  $F$ ) e  $\hat{\Lambda}$  estima  $\Lambda H^{-1}$  (uma rotação de  $\Lambda$ ), onde  $H$  é qualquer matriz  $r \times r$  invertível. Desta forma não é possível identificar os fatores comuns e *loadings* de forma única, embora o produto  $\hat{F}\hat{\Lambda}$  estime  $F\Lambda$  diretamente. Esta falta de identificação não é problemática para previsão, mas deve ser considerada quando os fatores são interpretados de maneira estrutural.

Para que os fatores possam ser estimados consistentemente pelo método de componentes principais, Bai e Ng (2002) e Bai (2003) mostram que os seguintes pressupostos devem ser atendidos<sup>1</sup>:

- *Pressuposto A – Fatores comuns:*  $E\|F_t\|^4 < \infty$  e  $T^{-1} \sum_{t=1}^T F_t F_t' \xrightarrow{p} \Sigma_F$  quando  $T \rightarrow \infty$  para alguma matriz  $r \times r$  positiva definida  $\Sigma_F$
- *Pressuposto B – Fatores loadings:*  $\|\lambda_i\| \leq \bar{\lambda} < \infty$  e  $\|\frac{\Lambda\Lambda'}{N} - \Sigma_N\| \rightarrow 0$  quando  $N \rightarrow \infty$  para alguma matriz  $r \times r$  positiva definida  $\Sigma_N$ .
- *Pressuposto C – Heterocedasticidade e Dependência no tempo e no cross-section:* Existe uma constante positiva  $M < \infty$ , tal que para todo  $N$  e  $T$ ,

<sup>1</sup>Os pressupostos A-D são os mesmos do trabalho de Bai e Ng (2002)

1.  $E(e_{it}) = 0$  e  $E|e_{it}|^8 < \infty$
2.  $E(e'_s e_t / N) = E(N^{-1} \sum_{i=1}^N e_{is} e_{it}) = \gamma_N(s, t)$ ,  $|\gamma_N(s, t)| \leq M$  para todo  $s$  e

$$T^{-1} \sum_{s=1}^T \sum_{t=1}^T |\gamma_N(s, t)| \leq M$$

3.  $E(e_{it} e_{jt}) = \tau_{ij,t}$  com  $|\tau_{ij,t}| < |\tau_{ij}|$  para algum  $\tau_{ij}$  e para todo  $t$ . Em adição,

$$N^{-1} \sum_{i=1}^N \sum_{j=1}^N |\tau_{ij}| \leq M$$

4.  $E(e_{it} e_{js}) = \tau_{ij,ts}$  e  $(NT)^{-1} \sum_{i=1}^N \sum_{j=1}^N \sum_{t=1}^T \sum_{s=1}^T |\tau_{ij,ts}| \leq M$
5. Para todo  $(t, s)$ ,  $E|N^{-1/2} \sum_{i=1}^N [e_{is} e_{it} - E(e_{is} e_{it})]|^4 \leq M$

- *Pressuposto D – Dependência fraca entre fatores e erros idiossincráticos:*

$$E \left( \frac{1}{N} \sum_{i=1}^N \left\| \frac{1}{\sqrt{T}} \sum_{t=1}^T F_t e_{it} \right\| \right)$$

Os pressupostos A e B asseguram que os fatores comuns e loadings não são degenerados. O pressuposto C permite que os componentes idiossincráticos  $e_{it}$  possuam formas fracas de heterosedasticidade e sejam fracamente correlacionados no tempo e entre as séries. O pressuposto D está implícito nos pressupostos A e C e permite que os fatores comuns sejam fracamente correlacionados com os erros idiossincráticos.

### 3.2 Modelo de Fatores Comuns Dinâmico

Uma generalização do modelo de fatores comuns estático em (1) é permitir que os fatores comuns afetem as séries de maneira contemporânea e também defasada. Esta nova configuração é chamada modelo de fatores comuns dinâmicos e pode ser expressa como:

$$X_t = \Lambda_0 \tilde{F}_t + \Lambda_1 \tilde{F}_{t-1} + \dots + \Lambda_s \tilde{F}_{t-s} + e_t \quad (6)$$

onde  $\tilde{F}_{t-j}$  são vetores  $q \times 1$  de fatores comuns e  $\Lambda_j$  são matrizes  $N \times q$  de fatores *loadings*, com  $j = 0, 1, \dots, s$ .

Se o número de defasagens  $s$  for finito, então, como mostra Stock e Watson (1998) e Bai e Ng (2007), o modelo de fatores comuns dinâmico em (6) é equivalente ao modelo de fatores comuns estático:

$$X_t = \Lambda F_t + e_t \quad (7)$$

com  $\Lambda = (\Lambda_0, \Lambda_1, \dots, \Lambda_s)$  e  $F_t = (\tilde{F}'_t, \tilde{F}'_{t-1}, \dots, \tilde{F}'_{t-s})'$

Isto mostra que um modelo com  $q$  fatores dinâmicos e  $s$  defasagens pode ser representado por um modelo com  $r = q(s+1)$  fatores estáticos. Esta equivalência entre os modelos permite aplicar todos os resultados teóricos - como estimação, especificação e inferência - do modelo de fatores estático ao modelo de fatores dinâmico na forma estática.

Vale ressaltar que o modelo de fatores comuns dinâmicos pode permitir que as defasagens  $s$  sejam infinitas, neste caso os procedimentos de estimação usam o conceito de componente principal dinâmico para estimar os fatores no domínio da frequência, como pode ser visto nos trabalhos de Forni et al. (2000) e Forni e Lippi (2011).

## 4 Previsão com fatores comuns

Uma das principais aplicações do modelo de fatores comuns é na previsão de séries macroeconômicas, como foi visto na revisão de literatura. Esta seção descreve o modelo de fatores de Stock e Watson (2002) e duas versões modificadas desse modelo propostas por Bai e Ng (2008) e Dias et al. (2010).

### 4.1 Modelo Índice de Difusão

Suponha que um grande conjunto de séries temporais estacionárias  $X_t = (X_{1t}, X_{2t}, \dots, X_{Nt})'$  são observadas para  $t = 1, \dots, T$ . O problema do agente econômico é prever  $y_{T+h}$ , estando em  $T$ . Uma solução para este problema é utilizar o modelo de Índice de Difusão (DI) proposto por Stock e Watson (2002) que consiste em usar os fatores comuns na seguinte equação de previsão:

$$y_{t+h} = \mu + \alpha(L)y_t + \beta(L)'F_t + \varepsilon_{t+h} \quad (8)$$

com  $F_t$  sendo um vetor  $r \times 1$  de fatores comuns satisfazendo:

$$X_{it} = \lambda_i'F_t + e_{it} \quad (9)$$

onde  $\alpha(L)$  e  $\beta(L)$  são polinômios de defasagem de ordem  $p$  e  $m$ , respectivamente,  $y_t$  é a variável a ser prevista e  $\mu$  é uma constante.

As equações (8) e (9) mostram como o modelo de fatores permite incorporar na previsão a informação de um grande número de preditores ( $X_t$ ) de uma maneira simples e parcimoniosa. O termo “índice de difusão” foi usado em Stock e Watson (2002) para designar os fatores comuns que representam os co-movimentos das variáveis econômicas. A ideia básica é estimar um pequeno número de fatores que expliquem a maior parte da variabilidade das variáveis observadas em , para depois usá-los como preditores.

O modelo DI é estimado em um procedimento de dois estágios; primeiro obtém-se os fatores comuns usando o estimador de componentes principais apresentado em (5). Com esses fatores estimados<sup>2</sup>, a equação de previsão em (8) é obtida usando Mínimos Quadrados Ordinários (MQO). O número de fatores comuns  $r$  e as ordens de defasagem  $p$  e  $m$  são escolhidas pelo Critério de Informação Bayesiano (BIC), com  $1 \leq r \leq 4$ ,  $1 \leq m \leq 3$  e  $1 \leq p \leq 6$ , onde os valores máximos escolhidos são os mesmo de Stock e Watson (2002).

Uma das críticas ao modelo DI de Stock e Watson (2002) é não considerar a variável específica que está sendo prevista. A partir desta crítica, dois refinamentos são propostos na literatura. O primeiro, denominado Índice de Difusão com preditores *targeted* (DI-tp), estabelece que as variáveis usadas para estimar os fatores comuns devem ser selecionadas considerando a variável específica a ser prevista. O segundo, chamado de Índice de Difusão com fatores *targeted* (DI-tf), propõe que se deve estimar o fator comum considerando a variável a ser prevista.

### 4.2 Modelo Índice de Difusão com preditores *targeted*

Apesar do modelo Índice de Difusão (DI) permitir a inclusão de um grande número de variáveis, o trabalho de Boivin e Ng (2006) tem evidenciado que simplesmente acrescentar mais

---

<sup>2</sup>Dado que o interesse é apenas na previsão gerada pelos fatores e não sobre os fatores em si, o problema de identificação inerente ao modelo de fatores é irrelevante neste caso.

variáveis para extrair os fatores comuns não é adequado quando o objetivo é previsão e as variáveis incluídas não são relevantes. Boivin e Ng (2006) mostram através de resultados empíricos que com um conjunto menor de variáveis macroeconômicas obtêm-se previsões com desempenho igual ou superior do que as obtidas com um conjunto maior de variáveis.

Motivados por este fato, Bai e Ng (2008) propõem um refinamento do modelo DI que denominaremos modelo Índice de Difusão com preditores *targeted* (DI-tp). O modelo DI-tp estabelece que as variáveis (preditores)  $X_{it}$  usadas para estimar os fatores comuns devem ser escolhidas considerando a variável específica  $y_t$  a ser prevista.

Por exemplo, se o objetivo é prever a inflação, então o conjunto de séries temporais usado para estimar os fatores comuns deve ser formado por variáveis que possuam alguma informação sobre a inflação futura.

Para determinar quais variáveis  $X_{it}$  são significativas para comporem o conjunto de dados usado na previsão de  $y_t$ , Bai e Ng (2008) propõe o método *hard thresholding* descrito a seguir:

- a) Para cada  $i = 1, \dots, n$ , efetua-se a regressão de  $y_t$  sobre  $W_{t-h}$  e  $X_{i,t-h}$ . Neste artigo  $W_{t-h}$  inclui uma constante e quatro defasagens de  $y_t$ .
- b) Denote por  $t_i$  a estatística  $t$  do parâmetro de  $X_{i,t-h}$ . c) Selecione os preditores  $X_{i,t}$  cuja  $|t_i|$  excede o nível de significância  $\alpha$ .
- c) Estime  $F_t$  a partir do conjunto de preditores selecionados e siga o mesmo procedimento padrão do modelo DI.

Além deste método *hard thresholding*, Bai e Ng (2008) propõem outros métodos de seleção denominados *soft thresholding* que aplicam algoritmos como *least absolute shrinkage selection operator* (LASSO) e *least angle regressions* (LARS). Este artigo utiliza apenas o *hard thresholding*, já que eles concluem que ambos os métodos são superiores em termos de erro de previsão quando comparados ao modelo DI padrão.

### 4.3 Modelo Índice de Difusão com fatores *targeted*

O modelo Índice de Difusão com fatores *targeted* (DI-tf) é outra configuração do modelo DI proposta por Dias et al. (2010) na qual a estimação do fator comum leva em consideração a variável  $y_t$  que está sendo prevista.

Para isto, considere a seguinte modificação, seja  $X_{(h)}$  uma matriz  $(T-h) \times N$  com os dados sem as últimas  $h$  observações. Como já visto na seção 3, os fatores podem ser estimados como:

$$\hat{\Lambda}_{(h)} = \sqrt{NV} \quad (10)$$

$$\hat{F}_{(h)} = X\hat{\Lambda}_{(h)}/N \quad (11)$$

onde agora  $V$  é uma matriz  $N \times N$  com as colunas sendo todos os auto vetores da matriz  $X'_{(h)}X_{(h)}$ .

A abordagem de Dias et al. (2010) consiste em gerar um fator comum *targeted* como uma combinação linear de todos os fatores estimados por componentes principais e a variável  $y_t$  a ser prevista da seguinte forma:

$$\hat{F}_{(h)t}^* = \sum_{n=1}^N \frac{\omega_{(h)n}}{\sum_{i=1}^N \omega_{(h)i}} \hat{F}_{(h)t,n} \quad (12)$$

com

$$\omega_{(h),n} = \left( \frac{1}{T-h} \sum_{t=1}^{T-h} \hat{F}_{(h)t,n} y_{t+h} \right) \frac{\mu_{(h),n}}{\mu_{(h),1}} \quad (13)$$

onde  $\hat{F}_{(h)t,n}$  é o elemento da linha  $t$  e da coluna  $n$  da matriz  $\hat{F}_{(h)}$ ,  $\mu_{(h),n}$  são os auto valores de  $X'_{(h)}X_{(h)}$ .

Estimado o fator *targeted*  $\hat{F}_{(h)t}^*$ , a previsão segue o mesmo procedimento do modelo DI padrão. A diferença que neste caso a equação de previsão possui apenas um fator comum,  $\hat{F}_{(h)t}^*$ , que considera a variável a ser prevista em sua estimação.

#### 4.4 Modelo Índice de Difusão com preditores e fatores *targeted*

Tendo apresentado duas formas diferentes do modelo DI como forma de melhorar as previsões, uma extensão natural é juntar essas duas formas de refinamento do modelo DI. Assim, o modelo Índice de Difusão com preditores e fatores *targeted* (DI-tfp) que é proposto neste artigo aplica a seleção de preditores igual ao modelo DI-tp e estima o fator comum da mesma forma que o modelo DI-tf, sendo, portanto, a combinação deste dois modelos. Desta forma, modelo DI-tfp considera a variável a ser prevista tanto na seleção dos preditores como na estimação dos fatores.

Apesar de simples, não encontramos na literatura nenhum trabalho que utilize essa extensão do modelo DI. Assim, este artigo também contribui ao propor esse novo modelo e ao investigar sua aplicabilidade na previsão da inflação no Brasil.

#### 4.5 Previsão de referência e previsões alternativas

Para comparar as previsões fora da amostra dos modelos índice de difusão é necessário um modelo de referência (*benchmark*). Este artigo escolhe a previsão da pesquisa Focus do Banco Central (BC) do Brasil como referência e duas previsões alternativas geradas pelos modelos autorregressivo integrado de média móvel (ARIMA) e vetor autorregressivo (VAR).

O modelo ARIMA é simples e frequentemente produz previsões melhores que outros modelos econométricos, como aponta Hamilton (1994, seção 4.8). Para a especificação e estimação usa-se o método automatizado descrito em Hyndman e Khandakar (2008).

O modelo VAR usa duas ou mais variáveis assumindo que as mesmas se relacionam simultaneamente para gerar previsões. De maneira semelhante à Arruda et al. (2011), a escolha das variáveis usadas no VAR foi obtida a partir das possíveis combinações do conjunto de variáveis PIB, taxa de juros Selic e agregado monetário M1.

A pesquisa Focus fornece a média e a mediana das previsões para a taxa de inflação acumulada em 12 meses para o horizonte de 12 meses à frente obtidas pelo BC com cerca de 100 participantes do mercado financeiro. Neste artigo utilizamos a mediana das previsões por apresentar menor EQM do que média no período em estudo. Como as previsões são coletadas diariamente pela Focus, usou-se a média dessas previsões diárias para representar a previsão mensal da Focus em determinado mês. Isto torna o conjunto de previsões da Focus compatível ao dos modelos que utilizam dados mensais.



## 5 Previsão fora da amostra

O tipo de previsão fora da amostra usado neste artigo é recursivo, i.e., todas as previsões são baseadas nos valores passados da série até a data em que a previsão é realizada, de forma que a especificação e os parâmetros do modelo são atualizados em cada período usando os dados do início da amostra até data corrente. Este tipo de previsão fora da amostra é também usado em Stock e Watson (2002), Bai e Ng (2008) e Dias et al. (2010).

O procedimento de previsão fora da amostra é uma forma de se obter previsões que se aproximam das previsões obtidas por agentes econômicos em situações reais. A vantagem deste procedimento é que permite quantificar a capacidade de adaptação do modelo a novos dados.

Outra vantagem da previsão fora da amostra é permitir comparar a previsões obtidas de modelos econométricos com previsões obtidas de outras formas ou quando não se conhece o modelo que gerou a previsão. No caso deste artigo, usam-se as previsões da pesquisa Focus e, portanto, não se tem o modelo econométrico gerador das previsões, já que as mesmas são recolhidas de um grande grupo de profissionais do mercado financeiro.

Vale ressaltar dois pontos. Primeiro, que este procedimento não é indicado quando o objetivo é avaliar modelos com base na teoria econômica, pois um modelo teórico válido pode gerar previsões menos acuradas do que um modelo de série temporal, conforme discute Clements e Demers (1998) e Shmueli (2010). No entanto, quando o objetivo é apenas previsão, o procedimento fora da amostra é uma forma intuitiva e factível de se avaliar previsões.

O segundo ponto é que testes para previsão fora da amostra não devem ser aplicados para comparação de modelos, visto que neste caso, os testes estatísticos tradicionais que usam toda a amostra, como o teste  $F$ , apresentam melhores resultados em termos de poder estatístico (Diebold, 2015).

Para complementar a análise de previsão fora da amostra, dois testes de previsão comumente usados na literatura são descritos a seguir.

### 5.1 Teste de igual acurácia de previsão

Ao comparar os erros de previsão de dois modelos é necessário identificar se a diferença observada é estatisticamente significativa ou não. Os testes usados para responder essa questão são chamados na literatura como testes de igual acurácia de previsão (*equal forecast accuracy*).

O teste DM modificado é baseado em Diebold e Mariano (1995) e Harvey et al. (1997) e permite verificar se a diferença de acurácia de previsão de dois modelos concorrentes é estatisticamente significativa. A estatística do teste DM inicialmente proposta por Diebold e Mariano (1995) é a seguinte:

$$S_1 = \frac{\bar{d}}{\sum_{\tau=-(h-1)}^{h-1} \frac{1}{T} \sum_{t=|\tau|+1}^T (d_t - \bar{d})(d_{t-|\tau|} - \bar{d})} \quad (14)$$

onde a série perda diferencial  $d_t = e_{A,t}^2 - e_{B,t}^2$  é a diferença dos erros quadrados das previsões<sup>3</sup> de dois modelos A e B,  $\bar{d}$  é a média amostral, o denominador é o estimador do erro padrão de  $\bar{d}$  robusto a heteroscedasticidade e autocorrelação,  $T$  é o tamanho da série  $d_t$  e  $h$  é o horizonte de previsão.

---

<sup>3</sup>A série perda diferencial pode ser definida para qualquer função perda,  $d_t = g(e_{A,t}) - g(e_{B,t})$ , neste artigo foi escolhida a função perda quadrática para comparar o erro quadrático médio.

A hipótese nula do teste DM é de que os dois modelos tem o mesmo desempenho de previsão, ou seja, a diferença média entre os erros de previsão dos modelos é zero,  $E(\bar{d}) = 0$ . Diebold e Mariano (1995) mostram que sob a hipótese nula e assumindo que a série  $d_t$  é estacionária, a distribuição assintótica da estatística  $S_1$  é normal padrão.

Harvey et al. (1997) sugerem um teste DM modificado para melhorar o desempenho do teste DM que consiste em utilizar a seguinte correção:

$$S_1^* = \sqrt{\frac{T+1-2h+T^{-1}h(h-1)}{T}} S_1 \quad (15)$$

onde  $S_1$  é a estatística original descrita em (14).

Além desta correção, deve-se comparar a estatística  $S_1^*$  com os valores críticos da distribuição  $t$  com  $T-1$  graus de liberdade para melhorar a performance do teste DM modificado em pequenas amostras.

## 5.2 Teste de previsão incorporada

Em previsão, mais importante que identificar o modelo com o menor erro de previsão é descobrir se modelos concorrentes possuem diferentes informações para prever uma variável de interesse, no sentido de que a combinação da previsão dos modelos seja melhor do que as previsões individuais.

Como observado por Harvey et al. (1998), um modelo concorrente que tenha alguma informação que é ausente no modelo de referência, é útil mesmo que possua erro de previsão maior, pois quando combina-se as previsões o erro diminui.

Essa questão da combinação de previsões de modelos rivais pode ser testada com uma simples regressão:

$$y_t = \alpha + (1 - \lambda)\hat{y}_{A,t} + \lambda\hat{y}_{B,t} + \varepsilon_t \quad (16)$$

onde  $\hat{y}_{A,t}$  e  $\hat{y}_{B,t}$  são as previsões para  $y_t$  obtidas de dois modelos  $A$  e  $B$  quaisquer,  $\alpha$  é uma constante e  $\varepsilon_t$  é o erro da regressão.

O parâmetro  $\lambda$  é estimado por Mínimos Quadrados Ordinários (MQO) e a inferência é realizada por um teste  $t$  com o procedimento de correção para heterocedasticidade e autocorrelação de Newey e West (1987). A hipótese nula ( $\lambda = 0$ ) é que o modelo  $A$  incorpora o modelo  $B$  em termos de previsão, ou seja, o modelo  $A$  incorpora a informação contida na previsão do modelo  $B$ . A hipótese alternativa ( $\lambda > 0$ ) é que o modelo  $B$  possui informações ausentes no modelo  $A$ .

## 5.3 Dados

Como o objetivo do artigo é avaliar o uso da grande quantidade de séries macroeconômicas para prever a inflação através de modelos índice de difusão, foi coletado um conjunto de dados suficientemente grande, de forma a obter séries temporais regulares e representativas da economia brasileira.

O conjunto de dados, o qual é detalhado no apêndice A, consiste de 122 séries temporais macroeconômicas de frequência mensal, cobrindo o período de 1996.1 a 2014.2 e oriundas do Ipeadata e Banco Central do Brasil. As séries são agrupadas em sete categorias:

- (1) Produção (19 séries);
- (2) Preços e indicadores monetários (16 séries);
- (3) Mercado externo (27 séries);
- (4) Finanças públicas (14 séries);
- (5) Consumo e vendas (15 séries);
- (6) Mercado de trabalho (13 séries);
- (7) Mercado financeiro (18 séries).

Para tornar o comportamento das séries estacionário, foi usado dois tipos de transformações. Na transformação log-diferença, o logaritmo natural da série é diferenciado em um período, o que representa uma aproximação da mudança mensal em termos percentuais. Na transformação primeira-diferença, as séries são apenas diferenciadas em um período.

Como é típico na literatura, as séries em valores correntes foram deflacionadas usando um índice de preços, nesse artigo foi escolhido o IPCA. A correção para valores discrepantes (*outliers*) seguiu o mesmo procedimento automático de Stock e Watson (2005)<sup>4</sup>.

## 6 Resultados Empíricos e Discussão

Nesta seção são analisados os resultados das previsões para inflação no Brasil usando os modelos índice de difusão na previsão da inflação, a pesquisa Focus e os modelos ARIMA e VAR. Todos os resultados foram obtidos com o programa estatístico R (R Core Team, 2016). Os códigos e os dados utilizados, assim como detalhes para replicação, estão disponíveis em <https://github.com/santoscs/prevendo.inflacao.fatores.comuns>

### 6.1 Comparando as previsões

O Índice de Preços ao Consumidor Amplo (IPCA) foi a medida de inflação escolhida por ser o índice oficial adotado pelo Banco Central (BC) do Brasil no sistema de metas de inflação. Os exercícios de previsão incluem dados de janeiro de 1996 até fevereiro de 2014. Este intervalo representa o período de estabilidade econômica após o plano real e possui uma grande quantidade de séries macroeconômicas disponíveis.

O IPCA acumulado em 12 meses é a série adotada pelo BC para monitorar o comportamento da inflação. Na publicação mensal “relatório da inflação”, o BC analisa e utiliza essa série, que ao fim do ano deve está dentro da meta estabelecida para inflação. Assim, não é de grande relevância prever que a inflação de um determinado mês será elevada, se a inflação em 12 meses ficar dentro meta. Além disso, grande parte dos agentes econômicos, quando fecham contratos e estabelecem seus preços para um determinado ano, também está mais interessada na inflação acumulada em 12 meses do que na inflação de um determinado mês.

Dado a importância da inflação acumulada nos próximos 12 meses, esse artigo avalia a capacidade dos modelos em prever a série do IPCA em 12 meses que é mostrada na Figura 1.

O horizonte de previsão é de 12 meses à frente. Esse é o mesmo horizonte de previsão usado na pesquisa Focus para prever a série IPCA acumulada em 12 meses. Além de possibilitar a comparação com a Focus, essa escolha do horizonte de previsão também é útil para o BC, dado o efeito defasado da política monetária.

---

<sup>4</sup>O ajuste para *outlier* corresponde a substituição da observação com desvio absoluto maior do que seis vezes o intervalo interquartil pelo valor mediano das cinco observações anteriores.




Figura 1: IPCA acumulado em 12 meses - 1996.1 - 2014.2

Fonte: Banco Central do Brasil. Elaboração dos autores.

Na simulação de previsão fora da amostra, todos os modelos foram estimados recursivamente do início da amostra até o período em que é realizada a previsão. As especificações dos modelos, como ordem de defasagem e número de fatores comuns, foram escolhidas pelo critério BIC.

Como medida da habilidade preditiva, utilizou-se a Raiz do Erro Quadrático Médio (REQM) e o Erro Quadrático Médio (EQM) relativo, que é simplesmente a razão entre o EQM do modelo e o EQM da pesquisa Focus. Um valor inferior a um desta razão indica de que o modelo possui um erro de previsão menor, ou seja, seu desempenho é melhor que a previsão da Focus.

A Tabela 1 apresenta a REQM e o EQM relativo dos modelos em relação à pesquisa Focus, junto com valor  $p$  do teste DM modificado para igualdade de previsão.

Tabela 1: Habilidade preditiva fora da amostra, 2008.5-2014.2

Modelo de Previsão	REQM <sup>1</sup>	EQM relativo <sup>2</sup>	Teste DM <sup>3</sup>
Pesquisa Focus	0,80	1,00	
ARIMA	1,02	1,64	0,33
VAR	1,58	3,92	0,00
Índice de Difusão (DI)	1,01	1,60	0,39
DI com fatores <i>targeted</i> (DI-tf)	1,03	1,67	0,38
DI com preditores <i>targeted</i> (DI-tp)	0,97	1,48	0,45
DI com fatores e preditores <i>targeted</i> (DI-tfp)	1,08	1,85	0,31

Fonte: Elaboração dos autores

<sup>1</sup> REQM: raiz do erro quadrático

<sup>2</sup> EQM relativo: EQM do modelo indicado dividido pelo EQM da pesquisa Focus.

<sup>3</sup> valor  $p$  do teste DM modificado cuja hipótese nula é que os erros de previsão são estatisticamente iguais ao da pesquisa Focus.

A REQM de 0,80 para a pesquisa Focus indica que, ao comparar o valor do IPCA em 12 meses com o previsto pela Focus, comete-se um erro “típico” de 0,80% para mais ou menos. A mesma interpretação é dada para a REQM dos demais modelos.

O EQM relativo mostra que a previsão da Focus para a inflação acumulada possui erro quadrático médio inferior ao de todos os modelos avaliados no período de maio de 2008 a fevereiro de 2014. Isto indica que a Focus é um bom modelo de referência (*benchmark*) quando se prevê a inflação acumulada em 12 meses. Este apontamento é corroborado por Altug e Çakmakli (2016) que indicam que a pesquisa Focus para inflação acumulada também supera as previsões da curva de Phillips *forward* e *backward-looking*.

Considerando-se o teste DM modificado, não há diferença significativa entre as previsões da Focus e dos modelos econométricos estimados para o IPCA acumulado no período de avaliação considerado, com exceção do modelo VAR, cujo valor  $p$  foi menor que 1%. Assim, apesar da Focus possuir menor EQM, não foi encontrada diferença estatisticamente significativa em relação ao EQM dos demais modelos.

Considerando somente as previsões da Focus para inflação mensal sem as previsões para a inflação acumulada em 12 meses, Lima e Alves (2011, p.16) concluem que “não há qualquer evidência significativa de superioridade das previsões da Focus sobre modelos univariados simples em horizontes mais longos de previsão”. Esses resultados apontam que, para a inflação, a eficiência preditiva da Focus é diferente quando usa-se a série mensal ou série acumulada em 12 meses. Trabalhos futuros podem estudar as duas séries de previsões conjuntamente para confirmar e explicar essa diferença.

## 6.2 Comparando as previsões combinadas

Apesar da Focus possuir previsões com o menor EQM entre os modelos analisados, não se deve concluir que os modelos usados não são úteis para prever a inflação com base apenas na comparação dos erros. Outra questão importante é saber se algum dos modelos possui informação adicional que é ausente na previsão da Focus, de forma que a previsão combinada tenha erros menores.

A Tabela 2 apresenta o resultado do teste de previsão incorporada (*forecast encompassing*) de Harvey et al. (1998) que investiga se o modelo  $A$  (primeira coluna) incorpora as informações contidas nas previsões do modelo  $B$  (segunda coluna). Ou seja, o testa-se agora se a previsão de algum dos modelos contém informação que é ausente na previsão da Focus.

Tabela 2: Teste de previsão incorporada, 2008.5-2014.2

Modelo $A$	Modelo $B$	$\hat{\lambda}$ (valor $p$ )
Pesquisa Focus	ARIMA	0,06 (0,85)
Pesquisa Focus	VAR	-0,17 (0,47)
Pesquisa Focus	Índice de Difusão (DI)	0,18 (0,26)
Pesquisa Focus	DI com fatores <i>targeted</i> (DI-tf)	-0,06 (0,83)
Pesquisa Focus	DI com preditores <i>targeted</i> (DI-tp)	0,24 (0,05)
Pesquisa Focus	DI com fatores e preditores <i>targeted</i> (DI-tfp)	0,03 (0,86)

Fonte: Elaboração dos autores

Nota: A tabela mostra o  $\lambda$  estimado na equação  $y_t = \alpha + (1 - \lambda)\hat{y}_{A,t} + \lambda\hat{y}_{B,t} + \varepsilon_t$ , onde  $y_t$  é o IPCA observado,  $\hat{y}_{A,t}$  é a previsão da pesquisa Focus e  $\hat{y}_{B,t}$  é a previsão do modelo na segunda coluna. A hipótese nula ( $\lambda = 0$ ) é que o modelo  $B$  não adiciona poder preditivo ao modelo  $A$ .

O teste de previsão incorporada mostra que a previsão da Focus incorpora a previsão de todos os outros modelos, com exceção do modelo DI-tp. Ou seja, apenas o modelo DI-tp contém informação que não está contida nas previsões do mercado fornecidas pela Focus. Isto evidencia ganhos de informação ao selecionar os preditores antes da estimação dos fatores comuns, visto que o

mesmo não ocorreu para modelos DI e DI-tf.

Esta evidência corrobora os resultados de Boivin e Ng (2006) e Bai e Ng (2008) de que mais variáveis no conjunto de preditores nem sempre é mais adequado quando se usa o modelo de fatores para previsão. Desta forma, estudos sobre previsão usando modelo índice de difusão e fatores comuns devem considerar a forma de como o conjunto de preditores é selecionado em suas especificações.

Vale ressaltar que é difícil para um modelo simples, como DI-tp, adicionar informação às previsões da Focus, já que a mesma é uma combinação das previsões de vários especialistas do mercado financeiro que usam diversos métodos e possuem diferentes conjuntos de informação.

Para reforçar as evidências do teste de previsão incorporada, a Tabela 3 compara a habilidade preditiva da previsão da Focus combinada com cada um dos modelos por meio de uma média aritmética simples. As combinações apresentarem um EQM relativo menor que um, indicando melhora na previsão em termos de erro, com exceção da combinação com o modelo VAR.

Tabela 3: Habilidade preditiva fora da amostra das previsões combinadas, 2008.5-2014.2

Modelo de Previsão	REQM <sup>1</sup>	EQM relativo <sup>2</sup>	Teste DM <sup>3</sup>
Pesquisa Focus somente	0,80	1,00	
Focus e ARIMA	0,72	0,82	0,41
Focus e VAR	1,09	1,88	0,00
Focus e Índice de Difusão (DI)	0,70	0,77	0,06
Focus e DI com fatores <i>targeted</i> (DI-tf)	0,77	0,94	0,72
Focus e DI com preditores <i>targeted</i> (DI-tp)	0,68	0,73	0,04
Focus e DI com fatores e preditores <i>targeted</i> (DI-tfp)	0,73	0,85	0,51

Fonte: Elaboração dos autores

<sup>1</sup> REQM: raiz do erro quadrático

<sup>2</sup> EQM relativo: EQM do modelo indicado dividido pelo EQM da pesquisa Focus.

<sup>3</sup> valor p do teste DM modificado cuja hipótese nula é que os erros de previsão são estatisticamente iguais ao da pesquisa Focus.

A previsão combinada com o modelo DI-tp apresentou uma redução no EQM de 27% em relação ao EQM da previsão somente da Focus, sendo a maior redução do EQM entre todas as combinações e a única com uma redução significativa ao nível de 5% conforme o teste DM modificado. Esta evidência reforça o resultado do teste de previsão incorporada da Tabela 2 mostrando que o modelo DI com preditores *targeted* apresenta informação que não consta nas previsões do mercado fornecidas pela pesquisa Focus.

Esta evidência também apoia o resultado encontrado por Figueiredo (2010) para inflação mensal no Brasil, de que o modelo de fatores com pré-seleção das variáveis (preditores *targeted*) apresenta melhor desempenho que outras abordagens de previsão com grande conjunto de dados, como Mínimos Quadrados Parciais (PLS).

## 7 Conclusão

Este artigo avaliou a aplicabilidade empírica de quatro modelos, índice de difusão (DI), índice de difusão com fatores *targeted* (DI-tf), índice de difusão com preditores *targeted* (DI-tp) e índice de difusão com preditores e fatores *targeted* (DI-tfp), que usam fatores comuns de um grande conjunto de séries macroeconômicas para prever a inflação no Brasil.

A avaliação se baseia em simulação de previsões fora da amostra, onde se compara os modelos índice de difusão com a pesquisa Focus do Banco Central do Brasil e com os modelos autorregressivo integrado de média móvel (ARIMA) e vetor autorregressivo (VAR).

As previsões da pesquisa Focus obtiveram a menor raiz do erro quadrático médio (REQM) entre todos os modelos quando se prevê a inflação acumulada um ano à frente. Isto ressalta a importância das previsões da Focus para monitorar a política monetária e para servir de referência (*benchmark*) quando se prevê a inflação acumulada em 12 meses.

Os resultados do teste de previsão incorporada indicam que apenas o modelo DI-tp adiciona informações à previsão da pesquisa Focus, de forma que a REQM da previsão combinada é menor do que a de cada previsão isoladamente. Nenhum outro modelo acrescentou informação às previsões da Focus de maneira significativa. Isto indica ganhos de informação ao selecionar os preditores de acordo com a variável a ser prevista. Vale ressaltar que estes resultados se limitam à inflação acumulada em 12 meses, podendo os modelos DI, DI-tf e DI-tpf ainda serem úteis para prever outras variáveis macroeconômicas.

Uma sugestão para trabalhos futuros é estudar modelos de fatores comuns para previsão que utilizem outros métodos de seleção dos preditores e verificar se as previsões da inflação melhoram em relação ao método de seleção usado neste artigo.

## Agradecimentos

Os autores agradecem à Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico (Funcap) pelo apoio financeiro.

## Referências

- Altug, S. e C. Çakmakli (2016). Forecasting inflation using survey expectations and target inflation: Evidence for Brazil and Turkey. *International Journal of Forecasting* 32(1), 138–153.
- Angelini, E., J. Henry, e R. Mestre (2001). Diffusion Index-Based Inflation Forecasts for the Euro Area. *European Central Bank Working Paper April*(61), 1–47.
- Arruda, E. F., R. T. Ferreira, e I. Castelar (2011). Modelos Lineares e Não Lineares da Curva de Phillips para Previsão da Taxa de Inflação no Brasil. *Revista Brasileira de Economia* 65(3), 237–252.
- Artis, M. J., A. Banerjee, e M. Marcellino (2005). Factor forecasts for the UK. *Journal of Forecasting* 24(4), 279–298.
- Bai, J. (2003). Inferential Theory for Factor Models of Large Dimensions. *Econometrica* 71(1), 135–171.
- Bai, J. e S. Ng (2002). Determining the Number of Factors in Approximate Factor Models. *Econometrica* 70(1), 191–221.
- Bai, J. e S. Ng (2007). Determining the Number of Primitive Shocks in Factor Models. *Journal of Business & Economic Statistics* 25(1), 52–60.
- Bai, J. e S. Ng (2008). Large dimensional factor analysis. *Foundations and Trends in Econometrics* 3(2), 89–163.

- Boivin, J. e S. Ng (2006). Are more data always better for factor analysis ? *Journal of Econometrics* 132, 169–194.
- Cheung, C. e F. Demers (2007). Evaluating forecasts from factor models for Canadian GDP growth and core inflation.
- Clements, M. e F. Demers (1998). *Forecasting Economic Time Series*. Cambridge: Cambridge University Press.
- Dias, F., M. Pinheiro, e A. Rua (2010). Forecasting using targeted diffusion indexes. *Journal of Forecasting* 29(3), 341–352.
- Diebold, F. X. (2015). Comparing Predictive Accuracy, Twenty Years Later: A Personal Perspective on the Use and Abuse of Diebold-Mariano Tests. *Journal of Business & Economic Statistics* 33(1), 1–24.
- Diebold, F. X. e R. S. Mariano (1995). Comparing Predictive Accuracy. *Journal of Business & Economic Statistics* 13(3), 134–144.
- Eickmeier, S. e C. Ziegler (2008). How successful are dynamic factor models at forecasting output and inflation? A meta-analytic approach. *Journal of Forecasting* 27(3), 237–265.
- Ferreira, R. T., H. J. Bierens, e I. Castelar (2005). Forecasting quarterly brazilian GDP growth rate with linear and non linear diffusion index models. *Revista EconomiA* 6(3 dec), 261–292.
- Figueiredo, F. M. R. (2010). Forecasting Brazilian Inflation Using a Large Data Set. *Working Paper Series do Banco Central* (228), 1–57.
- Forni, M., M. Hallin, M. Lippi, e L. Reichlin (2000). The generalized dynamic factor model: Identification and estimation. *The Review of Economics and Statistics* 82(4), 540–554.
- Forni, M. e M. Lippi (2011). The general dynamic factor model: One-sided representation results. *Journal of Econometrics* 163(1), 23–28.
- Gavin, W. T. e K. L. Kliesen (2008). Forecasting inflation and output: Comparing data-rich models with simple rules. *Federal Reserve Bank of St. Louis Review* 90(3), 175–192.
- Gupta, R. e A. Kabundi (2011). A large factor model for forecasting macroeconomic variables in South Africa. *International Journal of Forecasting* 27(4), 1076–1088.
- Hamilton, J. D. (1994). *Time Series Analysis*. New Jersey: Princeton University Press.
- Harvey, D., S. Leybourne, e P. Newbold (1997). Testing the equality of prediction mean squared errors. *International Journal of Forecasting* 13(2), 281–291.
- Harvey, D. I., S. J. Leybourne, e P. Newbold (1998). Tests for Forecast Encompassing. *Journal of Business & Economic Statistics* 16(2), 254–259.
- Hyndman, R. J. e Y. Khandakar (2008). Automatic time series forecasting: The forecast package for R. *Journal Of Statistical Software* 27(3), C3–C3.
- Lima, E. C. R. e P. P. Alves (2011). O desempenho do mercado (Focus) na previsão da inflação: Novos resultados? *Texto para Discussão, Instituto de Pesquisa Econômica Aplicada (IPEA) jun(1621)*, 1–25.
- Moser, G., F. Rumler, e J. Scharler (2007). Forecasting Austrian inflation. *Economic Modelling* 24(3), 470–480.



- Newey, W. e K. West (1987). A Simple, Positive Semi-Definite, Heteroscedasticity and Autocorrelation Consistent Covariance Matrix. *Econometrica* 55(3), 703–708.
- R Core Team (2016). R: A language and environment for statistical computing. *R Foundation for Statistical Computing, Vienna, Austria*.2, –.
- Schumacher, C. e C. Dreger (2004). Estimating large-scale factor models for economic activity in germany: Do they outperform simpler models? *Jahrbucher fur Nationalokonomie und Statistik* 224(6), 731–750.
- Shmueli, G. (2010, aug). To Explain or to Predict? *Statistical Science* 25(3), 289–310.
- Stock, J. H. e M. W. Watson (1998). Diffusion Indexes. *NBER Working Paper Serie* (6702), 1–55.
- Stock, J. H. e M. W. Watson (2002). Forecasting Using Principal Components From a Large Number of Predictors. *Journal of the American Statistical Association* 97(460), 1167–1179.
- Stock, J. H. e M. W. Watson (2005). Implications of Dynamic Factor Models for VAR Analysis. *NBER Working Paper Series* 11467, 1–67.

## Apêndice A

Tabela A.1: Descrição das séries macroeconômicas utilizadas

Séries macroeconômicas	Unidade	Identificador	Transf.
<b>1 – Produção</b>			
PIB	R\$	521274780	4
Expedição de caixas - papelão ondulado	Unid.	31873	3
Produção - petróleo - média	Barris/dia	32194	3
Produção física – alimentos	Índice	31845	3
Abate - bovinos - peso das carcaças	Kg (mil)	35921	3
Abate - suínos - peso das carcaças	Kg (mil)	35923	3
Produção - aço bruto	Kg (mil)	36495	3
Produção - cimento	Kg (mil)	37660	3
Produção - caminhões - montados	Unid.	600803224	3
Produção - ônibus - montados	Unid.	600803227	3
Produção - automóveis - montados	Unid.	600803230	3
Produção industrial - bens de capital	Índice	1506214474	3
Produção industrial - bens intermediários	Índice	1506214519	3
Produção industrial - bens de consumo	Índice	1506214564	3
Produção industrial - bens de consumo duráveis	Índice	1506214609	3
Produção industrial - bens de consumo não duráveis	Índice	1506214652	3
Produção industrial - indústria geral	Índice	1506214698	3
Produção industrial - indústria de transformação	Índice	1506214787	3
Utilização da capacidade instalada – indústria	%	33210	0
<b>2 – Preços e indicadores monetários</b>			
M0 - média	R\$	32130	4
M1 - média	R\$	32133	4
IPA origem - prod. agropecuários	Índice	33670	3

Tabela A.1: Descrição das séries macroeconômicas utilizadas

Séries macroeconômicas	Unidade	Identificador	Transf.
IPA origem - prod. industriais	Índice	33672	3
Inflação - INPC	% a.m.	36473	0
Cesta básica - município de São Paulo	R\$	38366	4
Inflação - IPCA	% a.m.	38513	0
Inflação - IGP-DI	% a.m.	39615	0
Inflação - IGP-OG	% a.m.	39617	0
Inflação - INCC	% a.m.	39618	0
Inflação - IPA-EP	% a.m.	39619	0
Inflação - ICV-SP	% a.m.	33239	2
Fatores condicionantes - papel-moeda emitido	R\$	39938	1
Fatores condicionantes - reservas bancárias	R\$	39939	1
Inflação - IPC (FGV)	% a.m.	39621	0
Inflação - IPC (FIPE)	% a.m.	34116	0
<b>3 – Mercado Externo</b>			
Exportações - rentabilidade	Índice	37821	3
Reservas internacionais - liquidez internacional	US\$	32289	2
Serviços e rendas - serviços	US\$	39421	2
Serviços e rendas - rendas	US\$	39424	2
Estados Unidos - índice Dow Jones - fechamento	Índice	39720	3
Estados Unidos - índice NASDAQ - fechamento	Índice	39721	3
Importações - bens de consumo duráveis	Índice	35579	3
Importações - bens de consumo não duráveis	Índice	35580	3
Importações - bens intermediários	Índice	35581	3
Importações - bens de capital	Índice	35582	3
Importações - quantum	Índice	35590	3
Importações - (FOB) - US\$	Índice	36915	3
Exportações - bens de consumo duráveis	Índice	35674	3
Exportações - bens de consumo não duráveis	Índice	35675	3
Exportações - bens intermediários	Índice	35676	3
Exportações - bens de capital	Índice	35677	3
Exportações - quantum	Índice	35690	3
Exportações - (FOB) - US\$	Índice	36916	3
Termos de troca	Índice	1693727000	3
Câmbio contratado - comercial	US\$	32284	0
Câmbio contratado - financeiro	US\$	32287	0
Paridade do poder de compra (PPC) - consumo das famílias	-	548454529	2
Taxa de câmbio - R\$ / US\$ - paralelo - venda - fim período	R\$	35918	3
Relação câmbio efetivo / salário	Índice	39875	3
Conta capital e financeira - conta capital	US\$	39418	0
Conta capital e financeira - conta financeira	US\$	39419	0
Transferências unilaterais correntes	US\$	39531	0
<b>4 – Finanças Públicas</b>			
Execução financeira - receitas	R\$	32226	4
Imposto sobre a circulação de mercadorias (ICMS)	R\$	32110	4
Execução financeira - despesas	R\$	32060	4
Dívida - total - gov. federal e Banco Central - líquida	R\$	32090	4

Tabela A.1: Descrição das séries macroeconômicas utilizadas

Séries macroeconômicas	Unidade	Identificador	Transf.
Imposto inflacionário - real - método 2B	R\$	36719	1
Imposto inflacionário - real - método 2A	R\$	36716	1
Imposto inflacionário - real - método 1B	R\$	36715	1
Imposto inflacionário - real - método 1A	R\$	36714	1
Dívida - total - estados e municípios - líquida	R\$	32088	4
Dívida fiscal - setor público - líquida	R\$	32072	4
NFSP - gov. federal e Banco Central - primário	R\$	1505384299	5
NFSP - estados e municípios - primário	R\$	1505384254	5
Fluxo de caixa da previdência - despesas	R\$	39057	4
Fluxo de caixa da previdência - recebimentos	R\$	1414756693	4
<b>5 – Consumo e vendas</b>			
Vendas de autoveículos*	Unid.	1378	3
Vendas nominais - indústria - SP	Índice	33696	3
Consumo - energia elétrica - comércio	GWh	38357	3
Consumo - energia elétrica - indústria	GWh	38358	3
Consumo - energia elétrica - outros setores	GWh	2027247947	3
Faturamento real - indústria - índice	Índice	33217	3
Inadimplência - índice em t-3	Índice	37852	2
Inadimplência - índice em t-4	Índice	37853	2
SPC - número de registros líquidos	Unid.	40075	2
Consumo aparente - derivados de petróleo - qde./dia	Barril	32035	3
Consumo aparente - bens de capital	Índice	39638	3
Consumo aparente - bens de consumo	Índice	848760088	3
Consumo aparente - bens de consumo duráveis	Índice	848760089	3
Consumo aparente - bens de consumo semi e não duráveis	Índice	848760090	3
Consumo aparente - bens intermediários	Índice	848760086	3
<b>6 – Mercado de trabalho</b>			
Horas trabalhadas - na produção - indústria - SP	Índice	33684	3
Horas pagas - indústria - SP	Índice	33692	3
Pessoal empregado - indústria	Índice	33212	3
Taxa de desemprego - RMSP	%	37655	3
Taxa de desemprego - aberto - RMSP	%	37656	3
Nível de emprego - indústria - SP	Índice	1684652394	3
Salário nominal - indústria - SP	Índice	33694	3
Folha de pagamento - indústria geral	Índice	39625	3
Emprego formal - Índice geral*	Índice	1586	3
Taxa de desemprego - oculto - RMSP	%	37657	3
Horas trabalhadas - indústria	Índice	33208	3
Salário real - médio - indústria - SP	Índice	33690	3
Rendimento médio - real - assalariados - RMSP	Índice	37654	3
<b>7 – Mercado Financeiro</b>			
Índice de ações - Ibovespa - fechamento	% a.m.	31875	0
Taxa de juros - Over / Selic	% a.m.	32241	3
Taxa de câmbio - R\$ / US\$ - comercial - venda - média	R\$	32101	3
Dólar comercial - rendimento nominal	Índice	32220	2
Fundo de ações - rendimento nominal	Índice	32210	2

Tabela A.1: Descrição das séries macroeconômicas utilizadas

Séries macroeconômicas	Unidade	Identificador	Transf.
Índice de confiança do consumidor (ICC)	Índice	40080	3
Índice de expectativas (IEC)	Índice	40082	3
Operações de crédito ao setor público	R\$	1067371625	4
Operações de crédito ao setor privado	R\$	1067371640	4
Operações de crédito ao setor privado - comércio	R\$	1067371633	4
Operações de crédito ao setor privado - imobiliário	R\$	1067371629	4
Operações de crédito ao setor privado - indústria	R\$	1067371627	4
Operações de crédito ao setor privado - outros serviços	R\$	1067371638	4
Operações de crédito ao setor privado - pessoas físicas	R\$	1067371636	4
Operações de crédito ao setor privado - rural	R\$	1067371632	4
Taxa de juros - CDI / Over	% a.m.	32237	3
Taxa de juros - TBF	% a.m.	32244	3
Taxa de juros - TR	% a.m.	32245	2

Fonte: Ipeadata.

Notas: \* dados do Banco Central do Brasil, Transformações: 0 sem transformação; 1 deflaciona; 2 primeira-diferença; 3 log-diferença; 4 log-diferença e deflaciona; 5 primeira-diferença e deflaciona.