TEXTO PARA DISCUSSÃO Nº 1172

MODELOS VETORIAIS DE CORREÇÃO DE ERROS APLICADOS À PREVISÃO DE CRESCIMENTO DA PRODUÇÃO INDUSTRIAL

Gilberto Hollauer
Luiz Dias Bahia
João Victor Issler

Brasília, março de 2006

TEXTO PARA DISCUSSÃO Nº 1172

MODELOS VETORIAIS DE CORREÇÃO DE ERROS APLICADOS À PREVISÃO DE CRESCIMENTO DA PRODUÇÃO INDUSTRIAL

Gilberto Hollauer*
Luiz Dias Bahia**
João Victor Issler***

Brasília, março de 2006

* Especialista em políticas públicas e gestão governamental.
** Técnico de planejamento e pesquisa da Diretoria de Estudos Setoriais (Diset) do Ipea.
*** EPGE-FGV, Rio de Janeiro.

Governo Federal

Ministério do Planejamento, Orçamento e Gestão

Ministro – Paulo Bernardo Silva
Secretário-Executivo – João Bernardo de Azevedo Bringel

ipea Instituto de Pesquisa Econômica Aplicada

Fundação pública vinculada ao Ministério do Planejamento, Orçamento e Gestão, o Ipea fornece suporte técnico e institucional às ações governamentais – possibilitando a formulação de inúmeras políticas públicas e programas de desenvolvimento brasileiro – e disponibiliza, para a sociedade, pesquisas e estudos realizados por seus técnicos.

Presidente
Glauco Arbix

Diretora de Estudos Sociais
Anna Maria T. Medeiros Peliano

Diretor de Administração e Finanças
Cinara Maria Fonseca de Lima

Diretor de Estudos Setoriais
João Alberto De Negri

Diretor de Cooperação e Desenvolvimento
Luiz Henrique Proença Soares

Diretor de Estudos Regionais e Urbanos
Marcelo Piancastelli de Siqueira

Diretor de Estudos Macroeconômicos
Paulo Mansur Levy

Chefe de Gabinete
Persio Marco Antonio Davison

Assessor-Chefe de Comunicação
Murilo Lôbo

URL: http://www.ipea.gov.br

Ouvidoria: http://www.ipea.gov.br/ouvidoria

ISSN 1415-4765

JEL C52

TEXTO PARA DISCUSSÃO

Publicação cujo objetivo é divulgar resultados de estudos direta ou indiretamente desenvolvidos pelo Ipea, os quais, por sua relevância, levam informações para profissionais especializados e estabelecem um espaço para sugestões.

As opiniões emitidas nesta publicação são de exclusiva e de inteira responsabilidade do(s) autor(es), não exprimindo, necessariamente, o ponto de vista do Instituto de Pesquisa Econômica Aplicada ou o do Ministério do Planejamento, Orçamento e Gestão.

É permitida a reprodução deste texto e dos dados nele contidos, desde que citada a fonte. Reproduções para fins comerciais são proibidas.

A produção editorial desta publicação contou com o apoio financeiro do Banco Interamericano de Desenvolvimento (BID), via Programa Rede de Pesquisa e Desenvolvimento de Políticas Públicas – Rede-Ipea, o qual é operacionalizado pelo Programa das Nações Unidas para o Desenvolvimento (Pnud), por meio do Projeto BRA/04/052.

SUMÁRIO

SINOPSE

ABSTRACT

1 INTRODUÇÃO **7**

2 MODELOS **8**

3 ANÁLISE DOS DADOS **11**

4 AVALIAÇÃO DOS MODELOS **16**

5 RESULTADOS **19**

6 CONCLUSÕES **22**

REFERÊNCIAS BIBLIOGRÁFICAS **24**

SINOPSE

Neste artigo são implementados e avaliados diferentes modelos econométricos de previsão para o PIB da indústria, dentro da classe de modelos vetoriais auto-regressivos (VAR), em freqüência trimestral, por vários procedimentos de teste e de modo intensivo. Em vários casos, usaram-se adicionalmente restrições de longo prazo advindas da co-integração entre as séries consideradas: o PIB industrial brasileiro, as taxas de juros longa e curta, a inflação, e a previsão dos saldos da indústria (proporção de firmas que crêem num aumento de produção no próximo trimestre, subtraída da proporção de firmas que crêem numa queda).

O poder preditivo dos diferentes modelos envolvendo essas variáveis foi avaliado a partir do uso de diferentes funções de perda (função dos erros de previsão de fora da amostra), que são avaliadas em uma janela móvel de tamanho fixo. Adicionalmente, considerou-se também a combinação das previsões de diferentes modelos, seguindo a literatura de combinação de previsões iniciada por Bates e Granger (1969). Conclui-se que o uso dos vetores de co-integração defasados como previsores – o *spread* da taxa de juros longa e curta, o *spread* entre os juros e a inflação, e a previsão dos saldos da indústria – em muito melhora a capacidade preditiva dos modelos considerados. Ademais, a combinação dos diferentes modelos de previsão, quer por média aritmética simples, quer por média ponderada, gerou, de forma geral, os melhores modelos de previsão para fora da amostra. Entretanto, houve casos em que modelos individuais tiveram um desempenho razoável e mesmo superior ao das combinações. Esses, no entanto, foram esporádicos. Logo, a sugestão recai sobre o uso de combinações de previsões como forma final de prever o PIB industrial.

ABSTRACT

In this paper we implement and evaluate several forecast econometric vectorial auto-regressive models for quarterly Industrial GDP. We have built co-integration vector restriction for several sets of variables (Industrial GDP, long interest rates, short interest rates, spread, inflation) in order to assess the improvement on forecast performance. A expectative variable of growth of industrial production among firms was also utilized and was proved to be valuable. The predictive power of different models was evaluated from diverse loss functions evaluated on out-of sample invariable size rolling-window method. Additionally, we have considered also combining forecast methods, following the subject literature which has been indicating this approach as one the most efficient (BATES e GRANGER, 1969).

We have concluded, the use of co-integration vector may improve substantially the forecast performance. Specialy, the interest rate spread has been proved to be a important leading indicator of industrial activity as well as the expectative variable (FGV). Furthermore, the c combining forecast models over-performed generally, apart others very good results of individual models.

1 INTRODUÇÃO

O objetivo central desse artigo é o de propor e avaliar modelos econométricos de previsão para o PIB da indústria. Usam-se modelos vetoriais auto-regressivos (VAR) em freqüência trimestral, aos quais se impõem restrições de longo prazo advindas da co-integração dentre as séries consideradas. Essas incluem, além do PIB industrial brasileiro, séries que tenham algum poder preditivo com relação a esse, como o *spread* da taxa de juros longa e curta, a taxa de juros real – o *spread* entre os juros e a inflação – , e a previsão dos saldos da indústria (proporção de firmas que crêem num aumento de produção no próximo trimestre, subtraída da proporção de firmas que crêem numa queda). O poder preditivo dessas variáveis é bem documentado na literatura internacional, *e.g.*, Stock e Watson (1993), Estrella e Mishkin (1999), e na literatura brasileira, *e.g.,* Duarte, Issler e Spacov (no prelo).

Restrições de co-integração, nesse contexto, dizem respeito ao fato de poderem existir séries econômicas que tenham uma raiz unitária no seu polinômio auto-regressivo, mas que, ao serem combinadas linearmente, eliminem a raiz unitária da combinação linear. Essas são de fato restrições quanto ao comportamento das séries econômicas no longo prazo, *e.g.*, o consumo e a renda não podem ter comportamento distinto a longo prazo. Exemplos desse fenômeno são freqüentes em economia, sendo que há alguns casos em que se obtém esse tipo de restrição com o do uso da teoria econômica e outros em que essas têm apenas uma motivação estatística (JOHNSTON; DiNARDO, 1997).

A avaliação dos modelos de previsão se dará através do uso de uma função-critério a ser minimizada, que é função dos erros de previsão de fora da amostra para cada possível modelo. Diferentes modelos dinâmicos serão considerados e a escolha recairá sobre aquele que obtiver o menor valor para essa função. Além de avaliar modelos específicos, seguindo o trabalho seminal de Bates e Granger (1969), considerar-se-á também a combinação de modelos como um potencial modelo de previsão. Como documentado na literatura de previsão, combinações de modelos prevêem bem porque pode haver instâncias em que um deles prevê bem enquanto outro mal, sendo que alguma combinação de ambos preverá melhor do que cada um individualmente. Ocorre aqui algo muito parecido com a literatura de finanças, que sugere a diversificação da carteira de ativos como estratégia de minimização de risco.

Ao final desse exercício econométrico, será possível escolher modelos de previsão, ou suas combinações, de forma a auxiliar na previsão da atividade industrial futura. Essa informação é relevante sob o ponto de vista governamental por pelo menos dois aspectos: primeiro, há a questão de saber-se o estado atual da economia e de poder-se prevê-lo num horizonte não muito longo; segundo, há a relevância de se poder prever com maior exatidão a arrecadação tributária, que é função do nível de atividade.

O trabalho está organizado como segue. Na parte dois, apresentam-se e discutem os modelos. Na parte três, analisam-se as séries utilizadas e testa-se a co-integração dessas. Na parte quatro, faz-se uma pequena digressão sobre a avaliação dos modelos. Na parte cinco, apresentam-se os resultados obtidos (JOHNSTON; DiNARDO, 1997).

2 MODELOS

2.1 MODELOS VETORIAIS AUTO-REGRESSIVOS

Muito embora possa conjeturar-se que modelos estruturados da economia sejam preferíveis a modelos não estruturados, após a crítica de Lucas (1976), o aparecimento da metodologia Box e Jenkins (1978) e a crítica de Sims (1980), os modelos estruturados de equações simultâneas deixaram o centro das atenções.

Lucas, em 1976, observou que o esforço na montagem de modelos estruturados muitas vezes caía por terra devido a alterações de políticas. Desse modo, os coeficientes mudavam de modo súbito quebrando estruturalmente o comportamento da série. Concomitantemente, Sims argumentou que as restrições impostas aos modelos estruturados para torná-los identificáveis eram demasiado fortes e que isso diminuía a eficácia e a qualidade da previsão.

Inspirada pela metodologia Box-Jenkins e a introdução dos modelos Arima (Auto-Regressive Integrated Moving Average) em 1978, a análise dos dados assumiu maior importância. Posteriormente, Sims introduziu o modelo Vetorial Auto-Regressivo (VAR), completamente não teórico, que suplantava a necessidade dos modelos estruturados de serem identificáveis, ademais, a aplicação da abordagem VAR se mostrou superior, em testes de performance de previsão, com respeito aos modelos estruturados (*e.g.*, LITTERMAN, 1986). Evidentemente, ainda que a escolha das variáveis relevantes dependa do problema e do modelo que o autor acredite existir em funcionamento, a liberdade admitida para essa construção passou a preponderar.

O modelo VAR de ordem p em k variáveis pode ser descrito como:

$$y_t = \sum_{i=1}^{p} A_i y_{t-i} + u + e_t \qquad (1)$$

Onde *y* é um vetor de n variáveis e *A* uma matriz *n x n*, sendo ε_t um vetor de ruído normal $N(0, \Sigma)$, com as propriedades usuais, é um vetor de intercepto. Obviamente, o tamanho da série, para a estimação por OLS deve superar em muito a quantidade de parâmetros, $n \times (np+1)$.

2.2 CO-INTEGRAÇÃO E MODELOS VETORIAIS DE CORREÇÃO DE ERROS (VECM)

Um processo é dito ser integrado de ordem b, y_t I(b) se a *b-ésima* diferença é um processo estacionário. Assim, em geral almejam-se processos *I(0).* Mais ainda, um processo vetorial y_t é dito ser co-integrado de ordem *d*, se existir um vetor c, tal que c' y_t *I(b-d).* Estritamente falando, as variáveis endógenas de um modelo VAR devem ser todas estacionárias, ou seja, integradas de ordem zero, *I(0),* portanto nesse contexto os autovalores da matriz A localizam-se todos no interior do círculo unitário. Resumidamente, considere o polinômio característico da equação (2):

$$|A(q)| = |I_k - A_1 q - ..... - A_p q^p| \qquad (2)$$

Se A(q) tiver uma ou mais raízes para q =1, A(1)=0, e as restantes fora do círculo unitário complexo, então o processo y_t é integrado e possivelmente co-integrado. Um

processo y_t *I(1)* será co-integrado se houver ao menos uma relação de co-integração (vetor de co-integração) dentre os *K-1* possíveis. Essas relações de co-integração são usualmente interpretadas como equilíbrios de longo prazo. Essa classe de VAR foi introduzida por Granger (1981) e Engle e Granger (1987). A inclusão de tais relações de longo prazo tem sido proveitosa no trabalho de previsão, como sugerem diversos estudos (CLEMENTS; HENDRY, 1995; ENGLE; YOO, 1987; LIN; TSAY, 1996).

Alguns autores indicam que, em se tratando de variáveis não estacionárias, digamos *I(1)*, o VAR deve ser realizado sobre as primeiras diferenças. Ocorre que o resultado obtido por meio de primeiras diferenças nem sempre é razoável (HARVEY, s/d), e de fato há informação nos níveis não sendo considerada. Um problema adicional se dá quando variáveis *I(0)* e *I(1)* se mesclam e nesse caso a simples diferenciação não resolve.

Ademais, assumindo a representação de Wold (HAMILTON, 1994), é possível ainda mostrar que na presença de co-integração a utilização de VAR para as diferenças não é consistente. Isto é, trabalhar com as primeiras diferenças em VAR é simplesmente inadequado, devendo o pesquisador voltar-se para os níveis em uma representação VAR ou para as primeiras diferenças em uma representação VECM. Devido a esses problemas, alguns trabalhos tratam com os modelos com níveis. Fazendo isso, advêm, de outro modo, duas dificuldades. A primeira concernente ao aparecimento de regressões espúrias em séries não estacionárias. O segundo problema é que as estimações e testes para regressões não estacionárias são não padronizados.

Um caso excepcional no qual se pode tratar com os níveis é quando da ocorrência de co-integração. Nesses casos pode-se mostrar que os estimadores são superconsistentes (*ibidem*), isto é convergem mais rapidamente do que o usual, e mantêm-se as informações sobre os níveis.

Havendo presença de co-integração, usualmente utiliza-se uma representação VECM (Vector Error Correction Model), que explicita a utilização do vetor de correção de erro que representa o comportamento de longo prazo:

$$\Delta y_t = B(L)\Delta y_t + a' b y_t + e_t \qquad e_t \approx N(0,\Sigma) \tag{3}$$

Essa representação pode ou não incluir uma variável exógena tanto no vetor de co-integração quanto externamente em termos de nível. De fato, Christoffersen e Diebold (1998) mostraram que a inclusão de variáveis exógenas no vetor de correção de erro pode melhorar a previsão do modelo em comparação com vetores de co-integração puramente endógenos. A inclusão de variáveis exógenas, quando econometricamente justificada, é também útil na medida em que ancora previsões condicionais, o que é conveniente em certas situações. Por exemplo, Landerretche, Morandé e Schmidt-Hebbel (2000) mostram que, no Chile, em relação a um preditor VAR para a inflação, sob regime de *inflation target*, a meta pré-anunciada era um preditor superior para a taxa de inflação *ex-post*, sugerindo a possibilidade de se construir um caminho para a variável exógena em uma previsão condicional. Mais ainda, o VAR incondicional sistematicamente sobreestimava a taxa de inflação para o período.

2.3 MODELOS VETORIAIS AUTO-REGRESSIVOS ESTRUTURAIS (SVAR)

Afora a simplicidade de aplicação dos modelos VAR em forma reduzida para a produção de previsões incondicionais, no que tange a previsões condicionadas a caminhos, talvez sejam modelos inadequados, e com mais propriedade modelos SVAR sejam utilizados. De fato, previsões incondicionais com VAR são mais simples e diretas. O problema da previsão condicional surge quando se imagina alguma correlação contemporânea entre as variáveis envolvidas e têm-se em mente cenários para algumas das variáveis.

Estritamente falando, a exogeneidade forte é necessária para a definição de caminhos das variáveis. Na ausência dela, a variável deveria ser, em princípio, colocada endogenamente ao modelo. Esse aspecto pode ser importante ao tratar-se com modelos de expectativas racionais, ou política monetária lastreada por metas de inflação. Nesse caso, a construção de cenários para a evolução de variáveis de controle é razoável, na medida em que é uma informação que não foi incluída explicitamente na modelagem, sendo difícil a sua imposição em modelos VAR. Naturalmente, sempre se pode argumentar que o analista em certo sentido, ao decidir a política monetária mais apropriada, toma ciência das séries envolvidas, endogeneizando a variável de controle. Neste trabalho, os SVAR não foram postos à prova, dada a ausência de exogeneidade forte. Em contrapartida, um modelo com componente exógena pré-determinada foi testado.

2.4 COMBINAÇÃO DE MODELOS (COMBINING FORECAST)

Algumas razões sugerem que a combinação de modelos pode construir previsões de performance superior (FANG, 2003). Primeiro, a pura diversificação de previsões leva à diminuição do erro diversificável. A segunda razão diz respeito à robustez, na medida em que, não sendo particular a uma especificação, não padece também de suas deficiências, além de incluir mais variáveis e informações de especificação de outros modelos, na medida em que se pesam informações de modelos que incluem outras variáveis e seus *lags*. Ademais, a experiência mostra que modelos parcimoniosos combinados possuem performance preditiva superior, até porque a sobreparametrização dos modelos VAR deteriora a sua performance preditiva. Nesse sentido, a combinação pode ser usada para examinar um número maior de variáveis, sem que seja necessário sobreparametrizar algum VAR em específico.

A combinação pode ser feita desde a simples média aritmética ou ponderada até a utilização de pesos adaptativos segundo a performance preditiva passada. Naturalmente, o ajuste dos pesos, normalizados ou não, pode ser feito por meio de mínimos quadrados ordinários (OLS), com ou sem termo constante. Especificamente:

$$\hat{y}_t^{\,C} = \sum_{n=1}^{N} \hat{w}_n \, \hat{y}_t^{\,n} \tag{4}$$

onde os $\hat{w}_n$ são os pesos e $\hat{y}_t^{\,n}$ são as previsões provenientes do modelo n para o instante t. No caso, se a escolha dos pesos for feita por meio de OLS sobre os erros cometidos, por exemplo, inclui-se uma memória no ajustamento. Freqüentemente impõe-se a condição de ausência de constante (não-enviesamento da combinação), bem como a normalização dos pesos com ou sem restrição de sinal $(\sum_{n=1}^{N} \hat{w}_n = 1, \hat{w}_n \geq 0)$. Outra

opção é realizar-se a composição sobre subgrupos das previsões, sob algum critério. Observa-se que a simples média aritmética possui uma performance superior aos métodos de OLS gerais (JORDAN; SAVIOZ, 2003). Finalmente, pode-se realizar a combinação posteriormente à seleção de subgrupos de modelos. Assim, primeiramente, faz-se uma pré-seleção em tempo real, dos modelos, e em seguida a combinação propriamente dita.

2.5 SELEÇÃO DA ORDEM DOS MODELOS

Usualmente, utilizam-se critérios de informação na determinação do número de defasamentos. Os critérios de informação mais freqüentes na literatura são o Critério de Akaike (AIC), Hannan-Quinn (HQ) e o Schwartz (SC ou BIC). Seja p a ordem do defasamento, n o número da amostra, considerado o mesmo para todas as variáveis (caso não seja trata-se de um NEAR-VAR). Nomeadamente os critérios são:

$$\begin{aligned} \mathrm{AIC} &= \ln|\Sigma(p)| + \frac{2}{\mathrm{T}}\mathrm{n}^2 p \quad \textit{Critério de Informação de Akaike} \\ \mathrm{HQ} &= \ln|\Sigma(p)| + \frac{2\ln(\ln(\mathrm{T}))}{\mathrm{T}}\mathrm{n}^2 p \quad \textit{Critério de Hannan-Quin} \\ \mathrm{BIC} &= \ln|\Sigma(p)| + \frac{2\ln(\mathrm{T})}{\mathrm{T}}\mathrm{n}^2 p \quad \textit{Critério de Schwartz} \end{aligned} \tag{5}$$

onde *p* é o *lag,* Σ é a matriz variância–co-variância dos resíduos, n a dimensão do sistema e T é o tamanho da amostra. Esses critérios objetivam a parcimônia dos modelos, impondo penalidades pelo número de regressores. Assim, embora a adequação, naturalmente, cresça, à medida que reduz a soma dos quadrados dos resíduos, com o número de variáveis acrescidas e com o aumento da ordem dos *lags*, tais critérios penalizam a escolha. A diferença entre os diversos critérios, além da origem, é o grau de severidade da penalização. Infelizmente, porque tais critérios impõem penalizações distintas, também escolhem modelos distintos.

Um segundo problema é que tais critérios são definidos *in-sample*. Isto significa que nada garante, em teoria, que o melhor modelo *in-sample* é o de melhor performance *out-of-sample* em previsões. Nesse tópico, apenas a pesquisa empírica é passível de servir de orientação. No entanto são de auxílio, na medida em que, dentre outras coisas, queremos decidir acerca de inclusão ou não de variáveis.

Lutkepohl (1985) focalizou a propriedade de pequenas amostras em modelos VAR bivariados e trivariados em uma simulação de Monte Carlo. O autor sugere que os critérios mais adequados seriam o Bayesian Information Criteria (BIC) e o HQ, e que o Akaike Information Criteria (AIC) sistematicamente sobreparametrizaria o modelo. Com respeito à performance dos critérios de informação, Gonzalo e Pitarakis (sem data) sugerem que o melhor critério é o AIC para sistemas VAR de grandes dimensões (K>4) em amostras moderadas, contrariamente à crença de que ele usualmente *overfits* o modelo.

3 ANÁLISE DOS DADOS

O critério de escolha das séries objetiva reforçar a capacidade de previsão, mais do que perseguir algum modelo pré-concebido, de modo que fomos levados – fazendo o uso

da correlação cruzada das séries e da indicação de causalidade de Granger das séries, individualmente, com o logaritmo do PIB industrial desazonalidado, naturalmente – a escolher séries antecedentes e causais ao PIB industrial. Experimentos outros detectaram que a inclusão de indicadores antecedentes *per si* melhorou a capacidade de previsão das séries (CAMACHO; PEREZ-QUIROS, 2002; HUH, 2002; HAMILTON; PEREZ-QUIROS, 1996; EMBESON; HENDRY, 1996; SALTOgLU; SENYÜZ; YOLDAS, 2003).

O maior problema consiste em que as séries, no Brasil, apresentam mudanças metodológicas em suas respectivas coletas, de modo que, por vezes, ou recorre-se a artifícios ou trabalha-se com amostras menores. No caso do PIB industrial, a série existe desde 1980. A produção física de papel e papelão, uma das séries testadas, e considerada um indicador coincidente relevante, por exemplo, foi descontinuada em 1991, pelo que foi reconstruída e conectada à série de produção física de papel, e papelão e celulose, dada a alta correlação de ambas.

A busca por indicadores antecedentes levou a considerar uma série que pesquisa a expectativa de aumento da produção do empresariado. A série utilizada foi a de sondagem industrial da Fundação Getúlio Vargas, existente desde 1966. Existem quatro séries, e em um *survey* de empresas do setor de transformação, computam-se os percentuais de *i*) empresas que esperam aumento de produção no trimestre seguinte, *ii*) diminuição de produção e *iii*) que a produção se mantenha em nível constante. A quarta série é uma *iv*) série de saldos entre previsões de crescimento e de diminuição da produção. Todas as séries mencionadas são séries de previsão de expectativas e existem desde 1978. Correspondentemente, existem quatro séries do que de fato foi observado *ex-post* à previsão.

Outras séries consideradas foram as de horas pagas pela indústria de transformação, de importações, de consumo de energia elétrica na indústria. É também de reconhecida importância o papel da taxa de juros na economia na previsão de PIB (ESTRELLA; MISHKIN, 1999), assim examinou-se a importância do juro real, como indicador antecedente, e do *spread* entre uma taxa de juros longa e uma taxa de juros curta referencial. A taxa de juros de curto prazo escolhida foi a Taxa Selic, que remunera as aplicações de curto prazo sendo a taxa referencial da economia, existente, em uma série concatenada, desde 1974. Uma dificuldade foi escolher uma série que servisse de *proxy* para uma taxa de juros de longo prazo. A escolha da série longa foi feita com base em análise de causalidade. Foram testadas séries de juros pré-DI Swap de 180 e 360 dias, bem como uma série de Certificado de Depósito bancário (CDB) de 30 dias a frente. Essa última, existente desde 1985, foi escolhida dado o tamanho da amostra existente; muito embora a série de *Swap* tenha tido resultados superiores na amostra comum, porque diminuta, implicaria a necessidade de reconstruir-se a série. Uma série promissora, também testada, mas que não apresentou significância no VAR, foi a série de crescimento do Ibovespa.

O índice de inflação escolhido foi o Índice de Preços no Atacado (IPA-OG), existente desde 1951, porque condizente com os custos industriais. Tendo testado todas as variáveis, chegamos a um conjunto pequeno de séries antecedentes da economia. Sendo elas, a taxa de inflação (IPA-OG), a taxa de juros curta (Selic), uma taxa de juros longa (CDB), o próprio PIB industrial e o indicador-saldo de expectativas (Ibre).

De modo a reduzir a variância, utilizamos, como usual, o logaritmo das variáveis. A desazonalização realizada pelo algoritmo X12 foi aplicada à série de nível do PIB Industrial e ao índice de expectativa, mas não às séries restantes. Ademais, as séries das taxas utilizadas foram escritas como Log(1+ π) sendo π a taxa. De modo análogo, adotou-se a utilização do logaritmo do PIB industrial.

FIGURA 1

Séries do logaritmo dos juros de longo prazo trimestral, do logaritmo dos juros de curto prazo, do logaritmo da taxa trimestral de inflação (IPA-OG), do logaritmo da produção industrial desazzonalidade e do saldo da expectativa desazonalizada

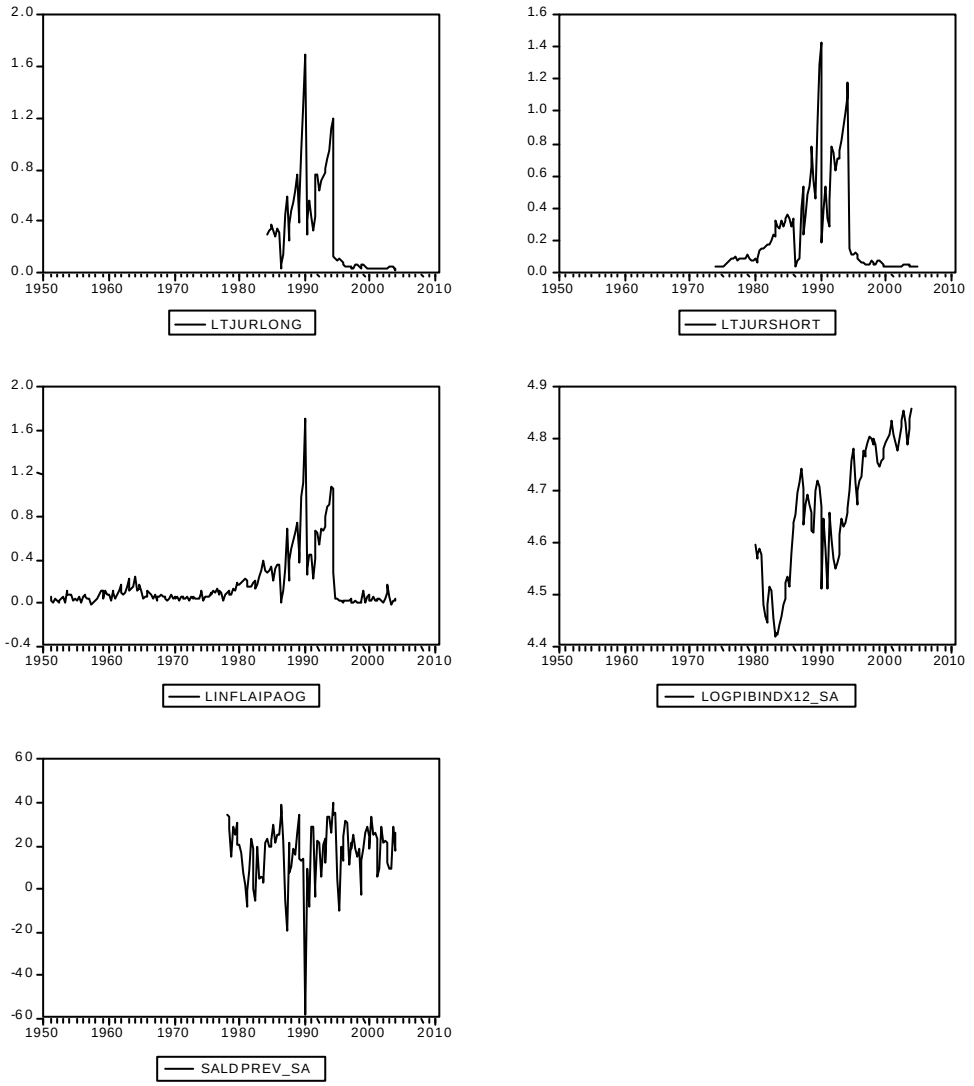

Elaboração dos autores.

3.1 TESTES DE ESTACIONARIDADE

A estacionaridade das séries de juros, do logaritmo do PIB industrial desazonalizado e da taxa de inflação foi testada utilizanda o teste ADF ajustado pelo critério de informação de Akaike e os resultados encontram-se a seguir. Observe-se que os tamanhos da amostra sendo diferentes, ao intervalo comum, a saber, a partir de 1984.2 até 2004.1:

TABELA 1

Teste de raiz unitária

	Em nível					Em diferenças			
	τ	τ_μ	τ_τ	I(.)		τ	τ_μ	τ_τ	I(.)
Log(PIB Ind.)	1.47	-2.04	-2.82	I(1)	Δlog(PIB Ind.)	-4.37[a]	-4.72[a]	-4.77[a]	I(0)
Selic	-2.07[b]	-2.29	-3.11	I(1)	ΔSelic	-7.49[a]	-7.44[a]	-7.41[a]	I(0)
CDB	-2.29[b]	-2.93[b]	-3.45[c]	I(1)	ΔCDB	-7.23[a]	-7.21[a]	-7.17[a]	I(0)
IPA-OG	-2.50[a]	-3.19[a]	-3.64[b]	I(1)	ΔIPA-OG	-7.64[a]	-7.60[a]	-7.56[a]	I(0)

Elaboração dos autores.

Obs.: τ significa sem intercepto, τ_μ com intercepto e τ_τ com intercepto e tendência. I(.) é a ordem de integração. "a" rejeita a 1%, "b" a 5% e "c" acima de 10%.

Tendo em vista a existência de choques externos, é prudente perfazer os testes de Perron (1997):

TABELA 2

Teste de Perron

	Em nível					Em diferenças			
	τ	τ_μ	τ_τ	I(.)		τ	τ_μ	τ_τ	I(.)
Log(PIB Ind.)	1.26	-2.18	-3.43[c]	I(1)	*D*log(PIB Ind.)	-9.65[a]	-9.78[a]	-9.74[a]	I(0)
Selic	-2.68[a]	-3.47[b]	-3.88[b]	I(1)	*D*Selic	-9.68[a]	-9.61[a]	-9.55[a]	I(0)
CDB	-3.09[a]	-3.93[a]	-4.45[a]	I(0)	*D*CDB	-10.78[a]	-10.70[a]	-10.63[a]	I(0)
IPA-OG	-3.44[a]	-4.38[a]	-4.84[a]	I(0)	*D*IPA-OG	-	-	-	I(0)

Elaboração dos autores.

Obs.: τ significa sem intercepto, τ_μ com intercepto e τ_τ com intercepto e tendência. I(.) é a ordem de integração "a" rejeita a 1%, "b" a 5% e "c" acima de 10%.

Finalmente, um último teste que considera o conjunto das séries é o teste de *ratio* da máxima verossimilhança sob a restrição da existência de um vetor de co-integração canônico. A imposição de vetores canônicos como vetores de co-integração é efetivamente um teste de raiz unitária. A realização desse teste classificou todas as séries como I(1) ao nível de 1%.

3.2 VETORES DE CO-INTEGRAÇÃO

3.2.1 Vetores de co-integração não restritos

A existência de co-integração é investigada utilizando a metodologia de Johansen (1988). O ajustamento do VAR, no primeiro momento, envolvendo todas as variáveis, é feito com base nos critérios AIC, BIC e HQ. Tendo os critérios BIC e HQ apontado uma estrutura de no máximo 1 *lag* enquanto o critério AIC apontava uma estrutura muito superior na amostra completa de 1984.4 até 2004.1, optou-se por uma estrutura parcimoniosa dos regressores, verificando-se, concomitantemente, o comportamento dos resíduos, que não apresentaram correlação serial. Testaram-se duas estruturas. A primeira, permitindo a existência de uma tendência linear e uma constante na relação de co-integração e, a segunda, sem tendência mas com intercepto na equação de co-integração. A estrutura mais significativa foi a sem tendência.

O teste do traço e do autovalor máximo é mostrado a seguir para os dois casos:

TABELA 3

Teste do traço, indicando ao nível de 1% e 5% a existência de três vetores de co-integração

Hipótese de		Estatística do Traço	5 %	1 %
Nº Integração	Autovalores		Valor Crítico	Valor Crítico
Nenhum**	0.465335	122.5132	68.52	76.07
No máximo 1 **	0.343638	73.67634	47.21	54.46
No máximo 2 *	0.279873	40.83496	29.68	35.65
No máximo 3	0.151852	15.22542	15.41	20.04
No máximo 4	0.030037	2.378793	3.76	6.65

Elaboração dos autores.

Obs.: * denota rejeição da hipótese a 5%;

** denota rejeição da hipótese a 1%.

TABELA 4

Teste de co-integração

Hipótese de		Estatística	5 %	1 %
Nº Integração	Autovalores	do max autovalor	Valor crítico	Valor crítico
Nenhum**	0.465335	48.83689	33.46	38.77
No máximo 1**	0.343638	32.84138	27.07	32.24
No máximo 2*	0.279873	25.60954	20.97	25.52
No máximo 3	0.151852	12.84663	14.07	18.63
No máximo 4	0.030037	2.378793	3.76	6.65

Elaboração dos autores.

Obs.: *denota rejeição da hipótese a 5%;

**denota rejeição da hipótese a 1%.

Os vetores de co-integração – três ao nível de 1% e de 5% – são dados abaixo, normalizados para o caso sem tendência linear e intercepto:

TABELA 5

Vetores de co-integração para o caso de tendência linear e intercepto

Log(PIB) (desazonal)	Saldo de previsão (desazonal)	Taxa de CDB	Taxa Selic	IPA-OG
1.000000	0.000000	0.000000	7.187421	-6.895700
			(1.27893)	(1.26771)
0.000000	1.000000	0.000000	304.2334	-296.5585
			(70.1386)	(69.5233)
0.000000	0.000000	1.000000	-2.309153	1.260234
			(0.31354)	(0.31079)

Elaboração dos autores.

Dois comentários são necessários. O primeiro diz respeito a heteroscedasticidade encontrada nos resíduos. Embora não altere os coeficientes, ela torna imprecisas as estimativas e valores de p. Por ora, apenas o desvio padrão associado ao OLS é apresentado, de qualquer forma, Gonzalo(1994) encontra pouco efeito de heteroscedasticidade sobre os resultados dos testes de co-integração, razão pela qual não faremos qualquer correção. Um segundo comentário diz respeito à interpretação econômica das variáveis. Ressalte-se que as taxas de juros longos reais surgem naturalmente, bem como o *spread*. Isso sugere uma estrutura mais parcimoniosa de co-integração.

3.2.2 Vetores de Co-Integração Restritos

Tendo observado a ocorrência natural do *spread* bem como das taxas reais de juros, passou-se a pesquisar relações de co-integração mais parcimoniosas. Foram adotados os seguintes vetores de co-integração: um vetor de co-integração para o saldo de previsão, dado que por construção essa variável é estacionária; um vetor de co-integração para o *spread* entre a taxa de juros longa e a taxa de juros curta; e um vetor de co-integração para os juros reais longos. A taxa real curta é tão somente uma combinação linear dos vetores precedentes e, portanto, não necessária. Essas restrições conjuntas foram aceitas ao nível de 5% na amostra inteira.

4 AVALIAÇÃO DOS MODELOS

4.1 MODELOS AVALIADOS

Tendo derivado as especificações possíveis para os modelos, passou-se ao exame dos seguintes modelos nos testes *out-of-sample*:

4.1.1 Modelo A: modelo univariado AR(4)

O modelo de *benchmark* escolhido foi um modelo AR(4), que melhor se adaptou à amostra pela abordagem de Box-Jenkins. O modelo é um modelo auto-regressivo de ordem dois e ruído com componente regressiva de ordem dois e quatro.

4.1.2 Modelo B: VECM irrestrito e com três vetores de co-integração

Esse modelo utiliza a especificação de três vetores de co-integração, estimados a cada janela, e atrasos unitários.

4.1.3 Modelo C: VECM restrito

O vetor restrito com vetores de co-integração impostos foi aceito a um *p-value* de 5% na amostra inteira. Tal estrutura é reestimada a cada janela, mantendo-se a especificação.

4.1.4 Modelo D: VAR em nível irrestrito.

É o modelo dinâmico irrestrito, reestimado a cada janela.

4.1.5 Modelo E: combinação de modelos por média aritmética

O primeiro método de combinação a ser testado é o da média aritmética dos modelos anteriores.

4.1.6 Modelo F: combinação de modelos por média ponderada

O segundo método utilizado foi de uma média ponderada quadrática da última previsão. Desse modo, quanto melhor a performance anterior, maior a sua importância na combinação.

4.2 TIPOS DE AVALIAÇÃO

Com respeito à avaliação de predição, existem quatro grandes linhas:

Abordagem de Amostra Completa ***(The Whole Sample Approach)***: Seleciona-se o modelo em uma amostra de (T_0 a T_1) observações, estimando-se o modelo sobre estas observações e em seguida avaliando-se o modelo no mesmo intervalo. Naturalmente, essa abordagem é apropriada quando se espera ocorrer a constância dos coeficientes da amostras.

Abordagem Recursiva ***(The Recursive Approach)***: Especifica-se e estima-se o modelo em uma amostra de T_0 a T_1, realizando-se predições h-passos à frente. Em seguida, reestima-se o modelo na janela de observações amostrais de T_0 a T_1+1, repetindo-se a previsão h-passos à frente. Isso é feito até que se tenha coberto toda a amostra disponível (DIEBOLD; RUDEBUSCH, 1991; SWANSON; WHITE, 1995).

Abordagem de Janela com Especificação Invariante ***(The Rolling-Window Approach with Invariant Specification)***: Nessa abordagem, a especificação é invariante e a janela de estimação sempre do mesmo tamanho. Assim, primeiramente, estima-se na janela amostral de T_0 até T_1. Realiza-se uma predição h-passos à frente e passa-se à estimação da janela seguinte de T_0+1 até T_1+1, realizando-se novamente uma predição h-passos à frente (SWANSON; WHITE, 1997, STOCK; WATSON, 1998). O tamanho da janela é assunto de natureza experimental e de disponibilidade de dados.

Abordagem de Janela com Especificação Adaptativa ***(The Rolling-Window Approach with Adaptive Specification)***: Semelhante a anterior, tendo contudo a possibilidade de alteração da especificação do modelo a cada nova janela. Isso significa que essa abordagem permite o ingresso de novo conjunto de informações à especificação.

4.3 INDICADORES DE PERFORMANCE

Vários indicadores têm sido desenvolvidos para avaliar e comparar a performance de modelos. Tais ferramentas estatísticas têm valor ao permitir o julgamento isento das vantagens dos modelos. Alguns indicadores são indicadores de precisão, outros são de adequação relativa e, finalmente, outros tentam capturar a capacidade de acerto de tendência dos modelos em questão; para uma revisão, consultem-se Diebold e Lopez (1996).

Avaliação de Acurácia ***(Evaluating forecasting accuracy):*** Os critérios usuais de avaliação incluem o valor médio quadrático dos erros de previsão (*mean squared forecast errors* (MSE)) ou a sua raiz quadrada (RMSE), o valor médio dos erros absolutos (MAE), o valor médio dos erros absolutos percentuais (MAPE), e o coeficiente de U-Theil.

O RMSE é dependente da escala e, em geral, é utilizado para comparação de preditores:

$$RMSE = \sqrt{\left[\frac{1}{n}\sum_{t=1}^{n}(\hat{y}_i - y_i)^2\right]} \tag{6}$$

onde n é o número de previsões avaliadas. Aqui cabe uma observação. As comparações são feitas entre previsões *i*-passos à frente, para o mesmo *i* e modelos distintos, então esses índices, rigorosamente, são indexados em *i*.

Uma variante possível é a generalização da potência de maneira a penalizar a maior dispersão, que deteriora fortemente a previsão da primeira diferença da série. A formulação seria, então, no caso testado, o caso de d-potência:

$$MdAE = \left[\frac{1}{n} \sum_{i=1}^{n} | \hat{y}_i - y_i |^d \right] \tag{7}$$

O MAE tem propriedades semelhantes e define-se como:

$$MAE = \left[\frac{1}{n} \sum_{i=1}^{n} | \hat{y}_i - y_i | \right] \tag{8}$$

O MAPE tenta capturar a importância do erro relativo e define-se como:

$$MAPE = \left[\frac{1}{n} \sum_{i=1}^{n} \frac{| \hat{y}_i - y_i |}{y_i} \right]. \tag{9}$$

Finalmente o coeficiente de U-Theil é a razão entre dois RMSE de previsões e varia entre 0 e 1, sendo escala-invariante:

$$THEIL = \frac{RMSE}{\sqrt{\left[\frac{1}{n} \sum_{i=1}^{n_2} (\hat{y}_i)^2 \right]} + \sqrt{\left[\frac{1}{n} \sum_{i=1}^{n_2} (y_i)^2 \right]}} \tag{10}$$

distintas, uma delas uma previsão de referência. Ou seja, o Theil faz uma razão entre uma previsão e uma previsão de referência, que é testada com uma estatística, havendo uma estatística associada.

Avaliação de Tendência de Previsão ***(Evaluating Direction-of-Change Forecasts)***: Afora previsões quantitativas, é mister argüir-se o acerto de tendência da previsão, ou quantas vezes uma predição, independentemente do erro cometido, acerta a tendência ou direção da previsão. Nessa linha, o *confusion index* (CI) calcula a proporção do tempo em que o modelo fornece tendências equivocadas. O cálculo é simplesmente a contagem desses eventos em uma mesma amostra. Afora esse índice simples, existem testes propostos por Pesaran e Timmermann (1992).

4.4 COMPARAÇÃO DE PREVISORES

Diversos testes para comparação de indicadores foram sugeridos (DIEBOLD; GUNTHER; TAY, 1998; HARVEY; NEWBOLD, 2000). Neste trabalho, utiliza-se a estatística Diebold-Mariano (DIEBOLD; MARIANO, 1995), como proposta por Harvey (1997). A estatística de Diebold e Mariano modificada por Harvey testa as seguintes hipóteses – nula e alternativa – sobre os indicadores escolhidos:

$$H0: G_o = G_p \tag{11}$$

$$H1: G_o > G_p$$

O teste da estatística utiliza as diferenças das funções-perda do modelo i, $g_i(\hat{u}_t)$, no caso, exemplificado, seja o indicador $G_i = \sum_k g_i(\hat{u}_k)$ e definimos

$d_t = g_0(\hat{u}_t) - g_p(\hat{u}_t)$ ou qualquer outro de interesse. No caso do MSE, a função perda é quadrática e no caso do MAE é simplesmente o módulo. Para *h*-passos à frente em um vetor de predições de comprimento n, a estatística MDM (Modified Diebold-Mariano) é dada por:

$$MDM = \sqrt{\frac{n+1-2h+n^{-1}h(h-1)}{n}} \frac{\bar{d}}{\sqrt{\hat{V}(\bar{d})}} \tag{12}$$

Onde $\bar{d} = n^{-1}\sum_{t=1}^{n} d_t$ e $\hat{V}(\bar{d}) = n^{-1}\left(r_0 + 2\sum_{i=1}^{h-1}\hat{r}_i\right)$ sendo

$$\hat{r}_i = n^{-1}\sum_{t=i+1}^{n}(d_t - \bar{d})(d_{t-i} - \bar{d})$$

No caso particular para h igual a um a expressão torna-se um OLS de uma constante. MDM possui então distribuição t com (n-1) graus de liberdade. Finalmente, a utilização da estatística de DM deve ser vista com alguma cautela, primeiro devido à baixa potência do teste e segundo porque não é apoiado em qualquer critério de informação. Nessa linha, simulações de Monte Carlo têm apontado tais deficiências e sugerido cuidados.

4.5 FORECASTING ENCOMPASSING

O conceito de *forecasting encompassing*, diferentemente da avaliação direta, prende-se à possibilidade de que uma combinação com performance superior pode ser obtida a partir das previsões obtidas. A sugestão de Clements e Hendry (1998) é testar a significância dos estimadores da regressão:

$$f = a_1 \hat{f}_i + a_2 \hat{f}_j + \hat{u} \tag{13}$$

Sujeito a $1 = a_1 + a_2$. Analogamente, a equação anterior pode ser reescrita para os desvios como sendo $\hat{u}_{j,h} = a(\hat{u}_{i,h} - \hat{u}_{j,h}) + \hat{v}$. Sob alguma significância, o teste acerca da não-nulidade de a significa testar se a previsão do modelo i, no passo h à frente, agrega informação à previsão do modelo j. Caso isso não ocorra, dir-se-á que o modelo j domina o modelo i.

5 RESULTADOS

5.1 RESULTADOS IN-SAMPLE

Utilizou-se a amostra completa, de 1984.3 até 2004.1, para comparação por meio dos critérios de informação.

TABELA 6

Valores calculados na maior amostra comum. Os modelos de combinação não estão exibidos

	Modelo A	Modelo B	Modelo C	Modelo D	Modelo E
Log L	148,59	192,79	186,65	172,80	137,42
Critério AIC	-3,63*	-3,40	-3,24	-3,61	-2,97
Critério SC	-3,48*	-1,59	-1,43	-2,71	-2,37
R2 Log(PIB)	0,852	0,72	0,93	0,70	0,907
$R2_{adj}$ Log(PIB)	0,844	0,69	0,92	0,67	0,902

Elaboração dos autores.
Obs.: O asterisco assinala o melhor modelo segundo cada critério.

5.2 RESULTADOS OUT-OF-SAMPLE

Para a análise fora da amostra, utilizou-se uma janela deslizante de 41 trimestres com especificação invariante, iniciando em 1984.2, sendo a primeira janela de 1984.2 até 1996.2, portanto na melhor hipótese produzindo uma amostra de 34 h-*steps ahead predictions*. Utilizou-se a previsão até oito passos adiante. Testes foram realizados utilizando-se os testes de Diebold e Mariano, para a função perda quadrática, função perda modular e a função perda com potência à quarta. Finalmente, utilizou-se um modelo Arima como *benchmark*.

TABELA 7

Modelos	Previsões à frente							
	1	2	3	4	5	6	7	8
Modelo A								
RMSE	0,00041	0,00100	0,00116	0,00148	0,00165	0,00176	0,00197	0,00218
Theil	0,00001	0,00002	0,00003	0,00003	0,00004	0,00004	0,00005	0,00005
MAE	0,02311	0,03698	0,04030	0,04394	0,04715	0,04604	0,04675	0,04852
CI	0,42424	0,54546	0,66667	0,60606	0,51515	0,46875	0,48387	0,53333
MDM-MSE	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000
MDM-MAE	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000
MDM-MdAE	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000
Modelo B								
RMSE	0,00034	0,00067	0,00097	0,00129	0,00152	0,00142	0,00127	0,00125
Theil	0,00001	0,00002	0,00002	0,00003	0,00004	0,00003	0,00003	0,00003
MAE	0,01793	0,02675	0,03494	0,04097	0,04277	0,04214	0,03825	0,03739
CI	0,36364	0,42424	0,63636	0,42424	0,45455	0,53125	0,45161	0,46667
MDM-MSE	-0,70766	-3,23950	-1,06741	-0,61057	-0,35837	-1,18750	-2,67971	-3,82136
MDM-MAE	-2,67961	-3,60947	-1,47897	-0,64265	-0,95586	-0,93330	-2,01014	-2,81202
MDM-MdAE	1,14448	-0,60412	-0,48613	0,35435	0,73405	-0,53165	-2,49342	-3,87605
Modelo C								
RMSE	0,00038	0,00084	0,00123	0,00168	0,00193	0,00179	0,00155	0,00143
Theil	0,00001	0,00002	0,00003	0,00004	0,00005	0,00004	0,00004	0,00003
MAE	0,01844	0,02889	0,03690	0,04136	0,04376	0,04342	0,04099	0,04125
CI	0,39394	0,51515	0,60606	0,48485	0,51515	0,46875	0,35484	0,46667
MDM-MSE	-0,30807	-1,06133	0,24423	0,38954	0,47912	0,04631	-0,86642	-2,08184
MDM-MAE	-2,25653	-2,55883	-0,72302	-0,42467	-0,55178	-0,44327	-1,00905	-1,45822
MDM-MdAE	1,24212	1,25406	1,28842	1,28592	1,31462	1,12779	0,60879	-0,82868
Modelo D								
RMSE	0,00016	0,00081	0,00172	0,00248	0,00312	0,00361	0,00401	0,00447
Theil	0,00000	0,00002	0,00004	0,00006	0,00007	0,00009	0,00010	0,00011
MAE	0,01447	0,03198	0,04947	0,05907	0,06516	0,07263	0,07924	0,08424
CI	0,27273	0,42424	0,51515	0,45455	0,45455	0,50000	0,38710	0,53333
MDM-MSE	-3,60862	-1,07161	3,15407	5,44834	6,92250	9,92894	13,40738	15,01558

(continua)

(continuação)

Modelos	Previsões à frente							
	1	2	3	4	5	6	7	8
MDM-MAE	-4,06956	-1,51481	3,26194	5,28922	6,13886	11,36593	15,63000	14,21878
MDM-MdAE	-3,06259	-0,44533	2,65060	4,45162	4,59832	6,44640	7,77730	8,73906
Modelo E								
RMSE	0,00026	0,00116	0,00242	0,00345	0,00427	0,00493	0,00563	0,00651
Theil	0,00001	0,00003	0,00006	0,00008	0,00010	0,00012	0,00013	0,00015
MAE	0,01719	0,03784	0,05438	0,06431	0,06935	0,07220	0,07707	0,08583
CI	0,24242	0,39394	0,42424	0,42424	0,48485	0,56250	0,45161	0,53333
MDM-MSE	-1,79536	0,68594	2,55302	2,54707	2,98596	3,15358	3,45901	4,20868
MDM-MAE	-2,29737	0,20814	2,48207	2,84414	3,01441	3,28051	3,81150	4,87327
MDM-MdAE	-1,48332	1,05301	2,28808	2,13499	2,43286	2,55067	2,37709	2,92487
Modelo F								
RMSE	0,00015	0,00047	0,00087	0,00113	0,00125	0,00118	0,00106	0,00100
Theil	0,00000	0,00001	0,00002	0,00003	0,00003	0,00003	0,00003	0,00002
MAE	0,01479	0,02495	0,03351	0,04054	0,04137	0,03904	0,03504	0,03337
CI	0,33333	0,48485	0,54546	0,39394	0,42424	0,59375	0,45161	0,53333
MDM-MSE	-4,34942	-3,89173	-2,01015	-1,50002	-1,66632	-2,59426	-3,80586	-4,77720
MDM-MAE	-5,06078	-4,38737	-2,20655	-0,90219	-1,64488	-2,01109	-3,11432	-4,13191
MDM-MdAE	-3,25913	-2,49922	-1,97782	-1,14548	-1,18701	-2,65933	-3,64358	-4,34042
Modelo G								
RMSE	0,00018	0,00053	0,00051	0,00063	0,00069	0,00056	0,00062	0,00059
Theil	0,00000	0,00001	0,00001	0,00002	0,00002	0,00001	0,00001	0,00001
MAE	0,01555	0,02527	0,02550	0,02964	0,02751	0,02707	0,02529	0,02504
CI	0,34375	0,46875	0,50000	0,46875	0,37500	0,38710	0,33333	0,51724
MDM-MSE	-2,76899	-1,97323	-4,36890	-3,85237	-3,83007	-4,70543	-4,82396	-5,22113
MDM-MAE	-2,99000	-2,69895	-4,38526	-3,32790	-4,46424	-4,51473	-4,92675	-5,45316
MDM-MdAE	-2,47341	-0,10041	-3,97930	-3,82437	-2,55338	-4,09371	-4,02960	-4,33545

Elaboração dos autores.

5.3 RESULTADOS DE ENCOMPASSING FORECASTING

O número de passos foi testado sob a significância de 5%. Para a análise fora da amostra, utilizou-se uma janela deslizante de 41 trimestres com especificação invariante, iniciando em 1984.2, sendo a primeira janela de 1984.2 até 1996.2, portanto na melhor hipótese produzindo uma amostra de 34 h-*steps ahead predictions*. Utilizou-se a previsão até oito passos adiante. Testes foram realizados utilizando-se os testes de Diebold e Mariano, para a função perda quadrática, função perda modular e a função perda com potência à quarta. Finalmente, utilizou-se um modelo Arima como *benchmark*.

TABELA 8

Modelo j pode ser melhorado incorporando-se informação do modelo i(hipótese nula: Modelo j não pode ser melhorado com i)		Previsões à frente (valor de p para a hipótese nula)							
		1	2	3	4	5	6	7	8
J	I								
2	1	0,00	0,00	0,01	0,00	0,00	0,01	0,04	0,05
3	1	0,00000	0,00000	0,00001	0,00000	0,00000	0,00000	0,00001	0,00001
3	2	0,03027	0,00107	0,00112	0,00046	0,00118	0,00200	0,00396	0,01125
4	1	0,06736	0,02469	0,00004	0,00000	0,00000	0,00000	0,00000	0,00000
4	2	0,23770	0,00009	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000
4	3	0,14604	0,00002	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000

(continua)

(continuação)

Modelo j pode ser melhorado incorporando-se informação do modelo i(hipótese nula: Modelo j não pode ser melhorado com i)		Previsões à frente (valor de p para a hipótese nula)							
		1	2	3	4	5	6	7	8
J	I								
5	1	0,00001	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000
5	2	0,01238	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000
5	3	0,05278	0,00010	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000
5	4	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000
6	1	0,07471	0,09750	0,06266	0,04719	0,04723	0,11092	0,23318	0,28051
6	2	0,02157	0,18179	0,17955	0,09675	0,04177	0,07387	0,11591	0,10203
6	3	0,01579	0,29920	0,40748	0,28120	0,26294	0,43319	0,40425	0,27241
6	4	0,05804	0,41993	0,41016	0,34148	0,29890	0,32686	0,37396	0,40152
6	5	0,37597	0,18254	0,14391	0,14806	0,16989	0,20992	0,27482	0,29035
7	1	0,01410	0,00361	0,14996	0,08154	0,12397	0,15014	0,29275	0,24645
7	2	0,00319	0,00299	0,40655	0,09471	0,15392	0,28251	0,11522	0,48116
7	3	0,02642	0,00743	0,46690	0,03974	0,02996	0,06246	0,00502	0,09266
7	4	0,01144	0,20040	0,43072	0,42976	0,44566	0,36000	0,41354	0,35500
7	5	0,12065	0,38368	0,15865	0,35914	0,38482	0,42319	0,22234	0,40898
7	6	0,00024	0,00468	0,44005	0,09148	0,13755	0,15602	0,06369	0,26715
1	2	0,00000	0,00000	0,00013	0,00013	0,00019	0,00006	0,00000	0,00000
1	3	0,00000	0,00000	0,00005	0,00005	0,00003	0,00000	0,00000	0,00000
2	3	0,33447	0,19516	0,25269	0,20346	0,29598	0,46159	0,35343	0,18319
1	4	0,00000	0,00018	0,41243	0,24248	0,08153	0,04039	0,04423	0,04017
2	4	0,00000	0,00771	0,09846	0,06969	0,03934	0,06384	0,09292	0,09528
3	4	0,00000	0,00001	0,00029	0,00011	0,00004	0,00003	0,00003	0,00002
1	5	0,00000	0,00000	0,00007	0,00004	0,00003	0,00001	0,00000	0,00000
2	5	0,00001	0,34775	0,12302	0,07290	0,11765	0,19391	0,27110	0,33089
3	5	0,00001	0,18579	0,12027	0,02494	0,02062	0,01212	0,00543	0,00177
4	5	0,04145	0,00032	0,00001	0,00000	0,00000	0,00000	0,00000	0,00000
1	6	0,00000	0,00000	0,00008	0,00009	0,00008	0,00001	0,00000	0,00000
2	6	0,00000	0,00005	0,01471	0,00514	0,00047	0,00134	0,00273	0,00104
3	6	0,00000	0,00000	0,00011	0,00002	0,00001	0,00002	0,00008	0,00013
4	6	0,01439	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000
5	6	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000
1	7	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000
2	7	0,49401	0,36705	0,00000	0,00003	0,00001	0,00000	0,00000	0,00000
3	7	0,17960	0,05031	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000
4	7	0,21436	0,00001	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000
5	7	0,00008	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000	0,00000
6	7	0,31084	0,24656	0,00001	0,00005	0,00002	0,00000	0,00002	0,00001

Elaboração dos autores.

6 CONCLUSÕES

Este artigo propôs-se a avaliar diferentes modelos econométricos de previsão para o PIB da indústria dentro da classe de modelos vetoriais auto-regressivos (VAR) em freqüência trimestral por vários procedimentos de teste e de modo intensivo. Em vários casos, usaram-se adicionalmente restrições de longo prazo advindas da co-integração entre as séries consideradas: o PIB industrial brasileiro, as taxas de juros longa e curta, a inflação, e a previsão dos saldos da indústria (proporção de firmas que crêem num aumento de produção no próximo trimestre subtraído da proporção de firmas que crêem numa queda).

O poder preditivo dos diferentes modelos envolvendo essas variáveis foi avaliado a partir do uso de diferentes função de perda (função dos erros de previsão de fora da amostra), que são minimizadas. Adicionalmente, considerou-se também a combinação das previsões de diferentes modelos, seguindo a literatura de combinação de previsões iniciada por Bates e Granger (1969).

Os resultados principais são os seguintes:

1. O uso dos vetores de co-integração defasados como previsores – o spread da taxa de juros longa e curta, o spread entre o juros e a inflação, e a previsão dos saldos da indústria – em muito melhora a capacidade preditiva dos modelos considerados.

2. A combinação dos diferentes modelos de previsão, quer por média aritmética simples, quer por média ponderada, gerou, de forma geral, os melhores modelos de previsão para fora da amostra. Porém, houve casos em que modelos individuais tiveram um desempenho razoável e mesmo superior ao das combinações. Esses, no entanto, foram esporádicos. Logo, a sugestão recai no uso dessas combinações de previsões como forma final de prever o PIB industrial.

A lista de sugestão para aperfeiçoamentos futuros inclui:

1. Levar em consideração a heteroscedasticidade presente nos resíduos dos modelos usados, fazendo correções nas estatísticas apropriadas, lembrando que esse fenômeno não gera viés nem inconsistência nas estimativas apresentadas acima.

2. Considerar futuramente modelos não lineares de várias formas, quer como modelos isolados, quer nas combinações de previsões.

3. Investigar a existência de características comuns de correlação serial (SCCF) entre as séries usadas, fenômeno que, se presente, admite a construção de modelos mais parcimoniosos, eficientes para a previsão do PIB industrial.

REFERÊNCIAS BIBLIOGRÁFICAS

CLEMENTS, M. P.; HENDRY, D. F. Forecasting in co-integrated systems. **Journal of Applied Econometrics. v.** 10, p. 127-146, 1995.

BATES, J. M.; GRANGER, C. W. J. The combination of Forecasts. **Operations Research Quarterly**, 20, 319-325, 1969.

BOX, G. E. P.; JENKINS, G. M. **Time Series Analysis**: Forecasting and Control. San Francisco: Holden Day, 1978.

CAMACHO, M.; PEREZ-QUIROS, G. This is what the leading indicators lead. **Journal of Applied Econometrics,** 117, p. 61-80, 2002.

CHRISTOFFERSEN, P. F.; DIEBOLD, F. X. 'Cointegration and Long-Horizon Forecasting'. **Journal of Business and Economic Statistics**, n. 16, p. 450-458, 1998.

CLEMENTS, M.; HENDRY, D. **Forecasting Economic Time Series.** Cambridge University Press, 1998.

DAVID, H.; NEWBOLD, P. Tests for multiple forecast encompassing. **Journal of Applied Econometrics**, v. 15, n. 5, p. 471-482, 2000.

DIEBOLD, F.; MARIANO, R. Comparing Predictive Accuracy. **Journal of Business and Economics Statistics**, 13, p. 253-265, 1995.

DIEBOLD, F. X.; GUNTHER, T. A.; TAY, A. S. Evaluating Density Forecasts with Applications to Financial Risk Management. **International Economic Review**, v. 39, n. 4, p. 863-883. Department of Economics, University of Pennsylvania and Osaka University Institute of Social and Economic Research Association, 1998.

DUARTE, A. J.; ISSLER, J. V.; SPACOV, A. D. Indicadores Coincidentes de Atividade Econômica e uma Cronologia de Recessões para o Brasil. **Pesquisa e Planejamento Econômico**, no prelo.

EMERSON, A.; HENDRY, D. An evaluation of forecasting using leading indicators. **Journal of Forecasting**, 15, p. 271-291, 1996.

ENGLE, R. F.; YOO, S. Forecasting and testing in co-integrated system. **Journal of Econometrics**, v. 35, p. 143-159, 1987.

ENGLE, R. F.; GRANGER, C. W. J. Co-integration and error-correction: representation, estimation and testing. **Econometrica**, 37, p. 424-438, 1987.

ESTRELLA, A.; MISHKIN, F. Prediciting U.S. recessions: financial variables as leading indicators. **Review of Economics and Statistics**, v. 80, p. 45-61, 1999.

FANG, Y. Forecasting Combination and Encompassing Tests. **International Journal of Forecasting**, 19, p. 87-94, 2003.

GRANGER, C. W. J. Some properties of time series data and their use in econometric models. **Journal of Econometrics**, 16, p. 121-130, 1981.

HAMILTON, J. D. **Time Series Analysis**. Princeton University Press, 1994.

HAMILTON, J.; PEREZ-QUIROS, G. What do the leading indicators lead? **Journal of Business**, 69, p. 27-49, 1996.

HARVEY, A. **The Econometric Analysis of Time Series**. 2. Ed. Cambridge, Massachusetts: The MIT Press.

HARVEY, B. Inference in TAR Models. **Studies in Nonlinear Dynamics and Econometrics**, 2, p. 1-14, 1997.

HUH, H. S. GDP growth and the composite leading index: a nonlinear causality analysis for eleven countries. **Economics Letters**, 77, p. 93-99, 2002.

GONZALO, J.; PITARAKIS, J. Y. Lag length Estimation in Large Dimensional Systems.

JOHNSTON, J.; DiNARDO. **Econometric Methods**. 4. ed. MCGraw-Hill Companies, Inc., 1997.

JOHANSEN, S. Statistical analysis of cointegration vectors. **Journal of Economic Dynamics and Control**, 12, p. 231-254, 1988.

JORDAN, T; SAVIOZ, M. Does it make sense to combine forecasts from VAR models? An empirical analysis with inflation forecasts for Switzerland. **Quarterly Bulletin**, 2003.

KUNST, R. Testing for relative predictive accuracy: a critical viewpoint. University of Vienna, presented at the METU Conference in Ankara, Sept. 2003. Disponível em: <http://elaine.ihs.ac.at/~webera/stokk.pdf>.

LANDERRETCHE, O.; MORANDÉ, F.; SCHMIDT-HEBBEL, K. Inflation Targets and Stabilization in Chile. *In*: MAHADIVA, L.; Sterne, G. (Eds.). **Monetary Policy Frameworks in a Global Context**. London: Rowtledge, 2000.

LIN J. L.; TSAY, R. Co-integration constraint and forecasting: an empirical examination. **Journal of Applied Econometrics**, v. 11, p. 519-538, 1996.

LITTERMAN, R. Forecasting with bayesian vector autoregressive-five years of experience. **Journal of Business and Economics Statistics**, v. 4, n. 1, p. 25-38, 1986.

LUCAS, R. E. **Econometric Policy Evaluation**: A Critique. North-Holland: Carnegie-Rochester Conference Series, 1976.

LUTKEPOHL, H. Comparison of criteria for estimating the order of a vector autoregressive process. **Journal of Time Series Analysis**, 6, p. 35-52, 1985.

PERRON, P. Further evidence on breaking trend functions in macroeconomic variables. **Journal of Econometrics**, v. 80, p. 355-385, 1997.

PESARAN, M. H.; TIMMERMMAN, A. A Simple Nonparametric Test of Predictive Performance. **Journal of Business and Economic Statistics**, 10, p. 461-465, 1992.

SALTOgLU B.; SENYÜZ, Z; YOLDAs, E. Modeling Business Cycles With Markov Switching Var Model: An Application On Turkish Business Cycles. **METU Conference in Economics**, VII, 6-9 Sept., Ankara, Turkey, 2003.

SIMS, C. Macroeconomics and Reality. **Econometrica**, v. 48, n. 1, p. 1-48, 1980.

STOCK, J., WATSON, M. A procedure for predicting recessions with leading indicators: econometric issues and recent experience. *In*: STOCK, J.; WATSON, M. (Eds.). **New research on business cycles, indicators and forecasting**. Chicago: University of Chicago Press, 1993.

© Instituto de Pesquisa Econômica Aplicada – **ipea** 2006

EDITORIAL

Coordenação
Ronald do Amaral Menezes

Supervisão
Iranilde Rego

Revisão
Lunde Braghini Júnior
Márcia Assunes Gonçalves
Naiane de Brito Francischetto (estagiária)
Sheila Santos de Lima (estagiária)

Editoração
Aeromilson Mesquita
Elidiane Bezerra Borges
Lucas Moll Mascarenhas

Brasília
SBS – Quadra 1 – Bloco J – Ed. BNDES, 9º andar
70076-900 – Brasília – DF
Fone: (61) 3315-5090
Fax: (61) 3315-5314
Correio eletrônico: editbsb@ipea.gov.br

Rio de Janeiro
Av. Nilo Peçanha, 50, andar – Grupo 609
20044-900 – Rio de Janeiro – RJ
Fone: (21) 2215-1044 – R.234
Fax: (21) 2215-1043 – R. 235
Correio eletrônico: editrj@ipea.gov.br

Tiragem: 130 exemplares

COMITÊ EDITORIAL

Secretário-Executivo
Marco Aurélio Dias Pires

SBS – Quadra 1 – Bloco J – Ed. BNDES,
9º andar, sala 908
70076-900 – Brasília – DF
Fone: (61) 3315-5374
Correio eletrônico: madp@ipea.gov.br