

Um Novo Índice Coincidente para a Atividade Industrial do Estado do Rio Grande do Sul

▪ IGOR ALEXANDRE C. DE MORAIS*

▪ MARCELO SAVINO PORTUGAL**

RESUMO

Este artigo utiliza o modelo de fator dinâmico de Stock e Watson para construir um índice coincidente que tenha um fundamento estatístico claro e que possa ser representativo do nível de atividade da indústria de transformação do Rio Grande do Sul. Além deste modelo linear, também é aplicada a metodologia de mudança de regime para caracterizar a assimetria no ciclo dos negócios na indústria do Estado, indicando os momentos de crescimento e queda na atividade econômica do setor com características diferenciadas. Este novo indicador é comparado com o índice de desempenho industrial (IDI) elaborado pela Federação das Indústrias do Estado do Rio Grande do Sul. Os resultados mostram que tanto o modelo linear quanto o não-linear estimam componentes que são altamente correlacionados como o índice de médias ponderadas atualmente calculado pela FIERGS.

PALAVRAS-CHAVE

Markov-switching, ciclo dos negócios, indicador coincidente, modelo de fator dinâmico

ABSTRACT

The present article uses the dynamic factor model of Stock and Watson to construct a coincident index with a clear statistical foundation able to represent the level of activity of the processing industry of the state of Rio Grande do Sul. In addition to this linear model, we also employ a regime switching methodology in order to determine the asymmetry of the business cycle in the industry on a statewide basis, pointing out periods of economic growth and stagnation in this sector. This new indicator is compared with the industrial performance index developed by the Federation of the Industries of the State of Rio Grande do Sul (FIERGS). The results show that both linear and nonlinear models estimate components that are highly correlated, such as the weighted average index currently calculated by FIERGS.

KEY WORDS

Markov-switching, business cycle, coincident indicators, dynamic factor model

JEL CLASSIFICATION

E32, O47

* Doutor em economia na UFRGS e coordenador da assessoria econômica da Federação das Indústrias do Estado do Rio Grande do Sul (FIERGS). E-mail: igor@fiergs.org.br.

** Professor do Programa de Pós-Graduação em Economia da UFRGS e pesquisador do CNPq. Agradeço a colaboração dos bolsistas de iniciação científica Philippe E. S. Berman (FAPERGS), Marcelo C. Griebeler (CNPq) Felipe G. Ribeiro (CNPq). E-mail: msp@ufrgs.br. End. para contato: Universidade Federal do Rio Grande do Sul Programa de Pós-Graduação em Economia – Av. João Pessoa 52, sala 33B – CEP: 90040-000 – Porto Alegre – RS.

(Recebido em agosto de 2004. Aceito para publicação em junho de 2006).

INTRODUÇÃO

O artigo seminal de Burns e Mitchell (1946) analisou as características dos ciclos dos negócios e despertou não apenas o interesse de pesquisadores sobre a existência de assimetrias entre as fases de crescimento e recessão presentes em uma economia, mas também a intenção de se construir indicadores econômicos que possam representar, e até antecipar, os movimentos da atividade econômica de um país. Estes indicadores são conhecidos na literatura econômica como coincidentes e antecedentes, existindo basicamente duas abordagens para construí-los.

A primeira pode ser creditada ao Departamento de Comércio dos Estados Unidos e é também utilizada pelo NBER (*National Bureau of Economic Research*). Ela está fundamentada em dois passos: inicialmente, com base em um critério de julgamento, são identificados os períodos de recessão e de crescimento da economia a partir da análise de diversas variáveis macroeconômicas. Posteriormente, os indicadores coincidentes e antecedentes são calculados utilizando a metodologia das médias móveis ponderadas. Apesar desta abordagem não ser fundamentada em um modelo probabilístico, carecendo de uma descrição precisa ou de uma definição do estado global da economia de um ponto de vista estatístico, ela tem sido útil para caracterizar o comportamento do ciclo dos negócios nos Estados Unidos nos últimos anos, mesmo que a decisão sobre uma recessão ou crescimento seja definida bem depois desta ter acontecido.

A segunda abordagem sobre indicadores coincidentes e antecedentes está fundamentada em uma modelagem estatística a partir do princípio de que a dinâmica das variáveis macroeconômicas pode ser representada por um componente não-observado. Este, por sua vez, representa o estado da economia sendo comum a todas as variáveis. Esta metodologia é dada pelo modelo de fator dinâmico.

Stock e Watson (1989, 1991) introduziram esta técnica, que passou a ser largamente utilizada na literatura econômica, em que os co-movimentos nas variáveis possuem um fator comum que pode ser mensurado por uma variável não-observada única, o estado da economia.¹ Neste modelo linear, o filtro de Kalman é utilizado para construir a função de verossimilhança que fornecerá a estimativa dos parâmetros do modelo a partir de sua maximização. Vale ressaltar que os tipos de movimentos comuns que duas ou mais variáveis macroeconômicas podem apresentar estão divididos entre os de longo prazo, caracterizados pela tendência comum, e que podem ser formulados

1 Para uma discussão sobre outras técnicas existentes que procuram caracterizar os ciclos econômicos, ver Filardo (1999). Para um modelo alternativo ao de Stock e Watson (1989, 1991) de indicadores antecedentes e coincidentes, ver Issler e Vahid (2000), aplicado posteriormente por Spacov (2001) para a economia brasileira. Vale ressaltar que neste modelo não é feita nenhuma restrição *a priori* sobre o número de ciclos comuns existente entre as variáveis que são analisadas para produzir um indicador coincidente.

a partir de um mecanismo de correção de erros, e os de curto prazo, que são denominados de ciclos comuns.² Porém, uma vez que existe uma sincronia no movimento de diversas variáveis econômicas, é perfeitamente factível que se reduza o número de variáveis a serem estudadas a fim de facilitar a interpretação dos dados sem que se perca a representatividade do ciclo econômico.

A abordagem do modelo de fator dinâmico linear considera a existência de simetria no ciclo dos negócios, ou seja, períodos de recessão e crescimento têm a mesma duração, magnitude e amplitude, tendo sido aplicada a séries macroeconômicas brasileiras com dois enfoques diferentes: Spacov (2001), com o intuito de construir um indicador coincidente e antecedente para a economia brasileira; e Picchetti e Toledo (2002), para produzir um indicador coincidente da produção física industrial com base nos índices das categorias de uso calculados pelo IBGE.

Mas, como pode ser visto em Diebold e Rudebusch (1996), a caracterização do ciclo dos negócios a partir do modelo linear, que descreve apenas os co-movimentos, estaria incompleta por não considerar também a existência de assimetria entre as fases destes ciclos. Uma forma de contornar este problema é permitir que o modelo não-linear de mudança de regime markoviano proposto por Hamilton (1989) seja incorporado à construção de um modelo de fator dinâmico.

Chauvet (1998) estima um modelo de fator dinâmico com base em um algoritmo desenvolvido por Kim (1994), que permite que o indicador resultante seja governado por uma variável de estado não observada. Esta formulação não-linear produziu resultados muito mais satisfatórios comparativamente ao modelo linear de Stock e Watson. Além disto, a previsão dos períodos de recessão e crescimento feitos pela autora coincide com os indicados pelo NBER para a economia americana. Vale ressaltar que uma das vantagens principais, do ponto de vista prático, do modelo de mudança de regime é que este pode ser utilizado para se fazer inferência em tempo real sobre o estado em que se encontra a atividade econômica.

Há uma série de outros trabalhos aplicando as metodologias linear e não-linear a diversas variáveis e problemas macroeconômicos. Forni *et alii* (2000a e 2000b), por exemplo, propõem uma nova metodologia para construir indicadores coincidentes e antecedentes, fundamentada na análise de fator dinâmico e de componente principal dinâmico, usando dados macroeconômicos de países da União Monetária Européia, sendo denominada de fator dinâmico generalizado. Este modelo permite que tanto o componente comum quanto o idiossincrático tenham uma representação dinâmica. Assim, os componentes comuns são calculados como a projeção dos dados futuros e

2 Vahid e Engle (1993) abordam a metodologia do ciclo comum, e Engle e Issler (1993) aplicam esta metodologia para investigar a existência de um comportamento comum entre o PIB do Brasil, Argentina e México.

passados do componente principal dinâmico, ao passo que o componente idiossincrático é calculado a partir dos resíduos ortogonais. Chauvet (2000) faz uma aplicação do modelo de fator para produzir indicadores antecedentes para a inflação no Brasil e Kholodilin (2002) utiliza um modelo de dois fatores para caracterizar o ciclo dos negócios na economia americana.

O propósito deste artigo é construir um índice composto a partir de cinco variáveis coletadas pela Federação das Indústrias do Estado do Rio Grande do Sul e que descrevem o nível de atividade da indústria de transformação do Estado do Rio Grande do Sul. São elas: vendas reais, compras reais, salários líquidos reais totais, horas trabalhadas na produção e utilização da capacidade instalada. Posteriormente, este novo indicador é comparado com o IDI (Índice de Desempenho Industrial), indicador de atividade atualmente calculado pela FIERGS, que está baseado no princípio da média móvel ponderada.

É importante destacar que a constituição deste novo indicador de atividade que não possua restrições *a priori* quanto aos pesos das variáveis envolvidas e que possa ser interpretado como resultante do comportamento geral do setor possui algumas vantagens. Em primeiro lugar, ele pode ser utilizado para monitorar o desempenho econômico em tempo real e, desta forma, determinar o ciclo dos negócios. Em segundo lugar, também pode ser útil futuramente quando da constituição de um indicador antecedente que venha a auxiliar na antecipação de choques econômicos diversos na indústria do Estado.

Neste trabalho serão desenvolvidas duas formulações para obter este novo indicador. A primeira está baseada no modelo de fator dinâmico linear de índice único desenvolvida originalmente por Stock e Watson (1989, 1991). A segunda é uma formulação não-linear e incorpora a mudança de regime no modelo de fator dinâmico. Enquanto o primeiro modelo tem como objetivo descrever apenas os co-movimentos cíclicos de diferentes variáveis da indústria, o segundo permite, além disto, a caracterização das assimetrias das diferentes fases do ciclo de negócios. Desta forma, será possível determinar os períodos de crescimento e de recessão que estiveram presente na indústria gaúcha durante a última década.

Este artigo está assim organizado: na seção 1 é descrita a metodologia do modelo de fator dinâmico linear, o modelo multivariado de fator com mudança de regime markoviano e o processo de estimação dos parâmetros que será utilizado; a seção 2 contém a descrição dos dados e os resultados dos testes estatísticos para os modelos linear e não-linear; a última seção apresenta as conclusões do trabalho.

1. METODOLOGIA UTILIZADA

1.1 Modelo Linear e Não-linear

Seja um vetor Y_{it} ($n \times 1$) composto do logaritmo de variáveis coincidentes, em que é assumido que todas as séries (y_{it}) possuem raiz unitária. A construção de um índice comum é feita a partir de um modelo de fator dinâmico com as variáveis medidas em nível. Neste caso, assumindo que estas sejam $I(1)$, é feita a primeira diferença, e o modelo tem o seguinte formato:

$$\Delta Y_{it} = D_i + \gamma_i \Delta C_t + \Delta u_{it} \quad (1.1)$$

$$(\Delta C_t - \delta) = \phi_1 (\Delta C_{t-1} - \delta) + \dots + \phi_r (\Delta C_{t-r} - \delta) + \eta_t \quad (1.2)$$

$$\Delta u_{it} = d_{i1} \Delta u_{it-1} + \dots + d_{ip} \Delta u_{it-p} + \varepsilon_{it} \quad (1.3)$$

em que $\eta_t \sim N(0, \sigma_\eta^2)$ é o choque comum, $\varepsilon_{it} \sim N(0, \Sigma_\varepsilon)$ é o erro de medida, a matriz de covariância é dada por $Q = \begin{pmatrix} \sigma_\eta^2 & 0 \\ 0 & \Sigma_\varepsilon \end{pmatrix}$, ΔC_t é o componente comum, δ é uma constante no tempo, $\sigma_{\eta_t}^2 = 1$, Δu_{it} é formulado de tal maneira a captar os efeitos dinâmicos dos choques, que são assumidos como independentes, e γ_i são os diferentes pesos do componente comum³ que medem a sensibilidade de cada série para com o ciclo dos negócios.

Como $E(\Delta Y_{it}) = E(D_i) + E(\gamma_i \Delta C_t) + E(\Delta u_{it}) = D_i + \gamma_i \delta$, o modelo acima pode ser expresso a partir do desvio das variáveis em relação à média. Desta forma, somando e subtraindo $E(\Delta Y_{it})$ da equação (1.1) temos:

$$\Delta Y_{it} - E(\Delta Y_{it}) = D_i + \gamma_i \Delta C_t + \Delta u_{it} - E(\Delta Y_{it}) \quad (1.4)$$

$$\Delta y_{it} = D_i + \gamma_i \Delta C_t + \Delta u_{it} - D_i - \gamma_i \delta \quad (1.5)$$

3 Para ser consistente com a restrição $\sigma_{\eta_t}^2 = 1$, as séries em Δy_{it} são padronizadas a partir de $\frac{\Delta y_{it}}{s_i}$ em que $s_i^2 = \frac{1}{N} \sum_{t=1}^n (\Delta y_{it} - \bar{y}_i)^2$.

$$\Delta y_{it} = \gamma_i (\Delta C_t - \delta) + \Delta u_{it} \quad (1.6)$$

$$\Delta y_{it} = \gamma_i \Delta c_t + \Delta u_{it} \quad (1.7)$$

em que $\Delta y_{it} = \Delta Y_{it} - E(\Delta Y_{it})$. Como $\Delta c_t = \Delta C_t - \delta$, a equação (1.2) passa a ser dada por:

$$\Delta c_t = \phi_1 \Delta c_{t-1} + \dots + \phi_r \Delta c_{t-r} + \eta_t \quad (1.8)$$

O problema estatístico a ser solucionado aqui é estimar Δc_t para cada $t = 1, \dots, n$ usando o conjunto de observações disponível até o momento t , ou seja, $\{c_t; t = 1, \dots, n\}$.

A solução proposta por Stock e Watson (1991) foi colocar as equações (1.1) – (1.3) no formato de espaço de estado e utilizar o filtro de Kalman para obter os hiperparâmetros do modelo. Uma vez feito isto, a estimativa de Δc_t corresponde ao índice coincidente, ao passo que as suas previsões para k períodos à frente estão relacionadas ao que se denomina de índice antecedente. O modelo de espaço de estado consiste de duas equações. A equação de medida descreve a relação entre as variáveis observadas (Δy_{it}) e as variáveis de estado não-observadas (Δc_t e Δu_{it}). Já a equação de transição irá descrever a dinâmica destas variáveis de estado ao longo do tempo.⁴

Assim, para o caso de cinco variáveis $\Delta y_{it} = (\Delta y_{1t} \ \Delta y_{2t} \ \Delta y_{3t} \ \Delta y_{4t} \ \Delta y_{5t})$ e o número de defasagens para Δc_t e Δu_{it} igual a dois, ou seja, $r=p=2$ em (1.3) e (1.8), as equações de medida e de transição são dadas, respectivamente, por:

$$\begin{bmatrix} \Delta y_{1t} \\ \Delta y_{2t} \\ \Delta y_{3t} \\ \Delta y_{4t} \\ \Delta y_{5t} \end{bmatrix} = \begin{bmatrix} \gamma_1 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ \gamma_2 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ \gamma_3 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ \gamma_4 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ \gamma_5 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} \Delta c_t \\ \Delta c_{t-1} \\ u_{1t} \\ u_{1t-1} \\ u_{2t} \\ u_{2t-1} \\ u_{3t} \\ u_{3t-1} \\ u_{4t} \\ u_{4t-1} \\ u_{5t} \\ u_{5t-1} \end{bmatrix} \quad (1.9)$$

4 Para uma descrição mais detalhada de modelos em formato de estado de espaço, ver Harvey (1989).

$$\begin{bmatrix} \Delta c_t \\ \Delta c_{t-1} \\ u_{1t} \\ u_{1t-1} \\ u_{2t} \\ u_{2t-1} \\ u_{3t} \\ u_{3t-1} \\ u_{4t} \\ u_{4t-1} \\ u_{5t} \\ u_{5t-1} \end{bmatrix} = \begin{bmatrix} \phi_1 & \phi_2 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & d_{11} & d_{12} & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & d_{21} & d_{22} & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & d_{31} & d_{32} & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & d_{41} & d_{42} & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & d_{51} & d_{52} \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} \Delta c_{t-1} \\ \Delta c_{t-2} \\ u_{1t-1} \\ u_{1t-2} \\ u_{2t-1} \\ u_{2t-2} \\ u_{3t-1} \\ u_{3t-2} \\ u_{4t-1} \\ u_{4t-2} \\ u_{5t-1} \\ u_{5t-2} \end{bmatrix} + \begin{bmatrix} \eta_t \\ 0 \\ \varepsilon_{1t} \\ 0 \\ \varepsilon_{2t} \\ 0 \\ \varepsilon_{3t} \\ 0 \\ \varepsilon_{4t} \\ 0 \\ \varepsilon_{5t} \\ 0 \end{bmatrix} \quad (1.10)$$

A representação na forma compacta destas matrizes é dada por:

$$\Delta y_t = H \beta_t \quad (1.11)$$

$$\beta_t = F \beta_{t-1} + v_t \quad (1.12)$$

em que Δy_t e β_t são vetores, H e F matrizes. O Filtro de Kalman pode ser inicializado por uma distribuição, *a priori*, difusa, e utilizado para gerar previsões para o vetor de estados. Stock e Watson (1991) utilizam este tipo de modelo com quatro variáveis da economia americana para calcular um indicador coincidente, acrescentando quatro defasagens para a variável emprego. Já Picchetti e Toledo (2002) aplicam o modelo acima, também com quatro variáveis, à economia brasileira, gerando um componente estocástico comum do índice de produção industrial.

É importante deixar claro que o modelo de fator dinâmico linear de Stock e Watson descrito em (1.11) e (1.12) considera apenas uma característica do ciclo dos negócios, qual seja, o co-movimento entre variáveis econômicas, deixando de incorporar, por exemplo, questões como a não-linearidade. Esta característica foi incorporada à descrição dos ciclos dos negócios por Hamilton (1989) a partir de um modelo univariado de mudança de regime aplicado ao PIB dos Estados Unidos. Posteriormente, em Chauvet (1998), a assimetria e o modelo de Stock e Watson foram abordados de forma conjunta em uma formulação denominada de “fator dinâmico multivariado com mudança de regime”.

Ao se permitir a existência de assimetria no ciclo dos negócios, a taxa de crescimento dos indicadores coincidentes observados (Δy_{it}) dependerá não apenas dos valores presentes e passados de um fator comum não observado (Δc_t), mas também do estado ou regime em que se encontra a economia. Desta forma, para incorporar esta característica, o conjunto de equações (1.1)–(1.3) passa a ser dado por:

$$\Delta Y_{it} = D_i + \gamma_i \Delta C_t + \Delta u_{it} \quad (1.13)$$

$$(\Delta C_t - \mu_{s_t} - \delta) = \phi_1 (\Delta C_{t-1} - \mu_{s_t} - \delta) + \dots + \phi_r (\Delta C_{t-r} - \mu_{s_t} - \delta) + \eta_t \quad (1.14)$$

$$\Delta u_{it} = d_{i1} \Delta u_{it-1} + \dots + d_{ip} \Delta u_{it-p} + \varepsilon_{it} \quad (1.15)$$

em que $\eta_t \sim N(0, \sigma_\eta^2)$, $\varepsilon_{it} \sim N(0, \Sigma_\varepsilon)$, ΔC_t é o componente comum, δ é uma constante no tempo, $\sigma_\eta^2 = 1$, todos os choques são independentes, γ_i são os diferentes pesos do componente comum e μ_{s_t} é determinado pelo estado em que se encontra a economia. Considerando a possibilidade de apenas dois estados, recessão ou crescimento, tem-se que:

$$\mu_{s_t} = \mu_0 + \mu_1 S_t \quad (1.16)$$

em que $\mu_1 > 0$, $S_t = \{0, 1\}$, e a transição entre estes estados é dada pela probabilidade de transição

$$\Pr[S_t = 1 / S_{t-1} = 1] = p \quad (1.17)$$

$$\Pr[S_t = 0 / S_{t-1} = 0] = q \quad (1.18)$$

em que p é a probabilidade de a indústria estar em crescimento em t , dado que estava em crescimento em $t-1$, e q é a probabilidade de a indústria estar em recessão em t , dado que também estava em recessão em $t-1$.

Note que, diferentemente do modelo linear utilizado por Stock e Watson, a formulação não-linear permite que a taxa de crescimento média de longo prazo do índice coincidente mude entre os dois regimes dos ciclos dos negócios. Esta taxa de cresci-

mento é dada por δ , e impondo para μ_{st} uma média zero, esta variável passa a representar os desvios desta taxa de crescimento de longo prazo de acordo com o estado da economia que, no caso $S_t = \{0, 1\}$, são dados pela recessão ou crescimento. Assim, o fator dinâmico estimado, além de representar o co-movimento entre as variáveis, pode também ser interpretado como o ciclo dos negócios.

Da mesma forma que no modelo linear, aqui também podem ser utilizados os desvios em relação à média, $\Delta y_{it} = \Delta Y_{it} - E(\Delta Y_{it})$ e $\Delta c_t = \Delta C_t - \delta$, para produzir as seguintes equações:

$$\Delta y_{it} = \gamma_i \Delta c_t + \Delta u_{it} \quad (1.19)$$

$$(\Delta c_t - \mu_{s_t}) = \phi_1 (\Delta c_{t-1} - \mu_{s_t}) + \dots + \phi_r (\Delta c_{t-r} - \mu_{s_t}) + \eta_t \quad (1.20)$$

que também podem ser colocadas no formato de estado de espaço. Para um modelo com cinco variáveis e duas defasagens para os componentes comum e idiossincrático, $r=p=2$, em (1.15) e (1.20), a equação de medida é a mesma equação (1.11). Porém, na equação de transição é acrescentado, do lado direito, o vetor⁵ $[\phi(L)\mu_{s_t} \ 0 \dots 0]$ com o objetivo de captar os diferentes regimes. De forma compacta, estas duas equações podem ser representadas por:

$$\Delta y_t = H \beta_t \quad (1.21)$$

$$\beta_t = \mu_{\phi(L)S_t} + F \beta_{t-1} + v_t \quad (1.22)$$

É importante ressaltar que além da formulação apresentada acima, em que a de regime ocorre na média, é possível ainda aplicar a mudança de regime também no intercepto do componente comum, como em Kim e Yoo (1995) e Kim e Nelson (2000a). Sendo assim, o intercepto pode ter dois valores, um pequeno nas recessões e outro maior nos períodos de crescimento, o que permite que o fator comum (Δc_t) apresente crescimento mais rápido durante os períodos de expansão e mais lento nos períodos de queda da atividade.

Contudo, nada garante que o conjunto de dados utilizado seja caracterizado por apenas um fator. Kim e Piger (2000b) estimam um modelo com dois fatores dinâmicos,

5 $\phi(L)\mu_{s_t} = \mu_{s_t} - \phi_1 \mu_{s_{t-1}} - \phi_2 \mu_{s_{t-2}}$.

ou seja, uma tendência estocástica e um componente transitório comum. Modelos com mais de um fator foram também utilizados por Engle e Issler (1995), Issler e Vahid (1998) e Kholodilin (2002).

1.1 Processo de Estimação

A estimação dos hiperparâmetros do modelo de fator dinâmico linear não apresenta maiores dificuldades.

Considere as seguintes equações de medida e de transição

$$\Delta y_t = H\beta_t + \varepsilon_t \quad (1.23)$$

$$\beta_t = \mu + F\beta_{t-1} + v_t \quad (1.24)$$

$$\begin{pmatrix} \varepsilon_t \\ v_t \end{pmatrix} \sim N \begin{pmatrix} R & 0 \\ 0 & Q \end{pmatrix}$$

de um modelo tal como representado por (1.1)–(1.3). Desta forma, os hiperparâmetros são obtidos a partir do uso do Filtro de Kalman,⁶ que calcula de forma recursiva o vetor de estados não observado no tempo t com base em toda a informação até $t-1$. Este processo consiste de dois passos. O primeiro é a previsão, em que, no início do tempo t , tem-se um previsor ótimo de Δy_t com base em toda a informação até $t-1$ (ψ_{t-1}), isto é, obtém-se $\beta_{t/t-1} = E[\beta_t / \psi_{t-1}]$. Neste caso, a matriz do erro quadrado médio de previsão é dada por $P_{t/t-1} = E[(\beta_t - \beta_{t/t-1})(\beta_t - \beta_{t/t-1})' / \psi_{t-1}]$.

No segundo passo tem-se disponível a informação para o período t (y_t) e, desta forma, pode ser calculado o erro de previsão que contém uma informação nova de β_t em relação à $\beta_{t/t-1}$. Portanto, uma vez conhecido y_t , pode ser feita uma melhor inferência sobre β_t , calculando-se $\beta_{t/t}$.

Porém, a partir do momento que se insere nas equações de medida e de transição a mudança de regime, os parâmetros do modelo passam a depender do comportamento de uma variável de valor discreto, $S_t=1,2,\dots,M$, que não é diretamente observada. Desta forma, no modelo de espaço de estado com mudança markoviana o objetivo passa a ser fazer uma previsão de β_t que seja baseada não somente em toda informação disponível até $t-1$ (ψ_{t-1}), mas também na variável aleatória S_t . Note que, agora, para

⁶ Ver Harvey (1989) para uma descrição detalhada sobre o Filtro de Kalman.

cada momento t da iteração tem-se M^2 estimativas do vetor de estado ($\beta^{(i,j)}_{t/t-1}$) dado por:

$$\beta^{(i,j)}_{t/t-1} = E[\beta_t / \psi_{t-1}, S_t = j, S_{t-1} = i] \quad (1.25)$$

e também M^2 diferentes matrizes de erro quadrado médio ($P^{(i,j)}_{t/t-1}$) dadas por:

$$P^{(i,j)}_{t/t-1} = E[(\beta_t - \beta_{t/t-1})(\beta_t - \beta_{t/t-1})' / \psi_{t-1}, S_t = j, S_{t-1} = i] \quad (1.26)$$

para todos os estados possíveis, que aqui são caracterizados por i e j .

Assim, a utilização do Filtro de Kalman para estimar estes parâmetros aumentaria de forma significativa o número de possibilidades a cada iteração. Para o caso de k regimes, teríamos M^k estimativas a cada iteração do filtro.

A alternativa encontrada por Kim (1994) foi utilizar um algoritmo de alisamento de forma a fazer o filtro básico colapsar sobre um número menor de parâmetros. Esta técnica pode ser aplicada, sob algumas restrições, para se obter inferência sobre qualquer modelo dinâmico de série de tempo com mudança de regime que possa ser colocado no formato de espaço de estado. A proposta de Kim (1994) é introduzir alguma aproximação no filtro com o intuito de reduzir a matriz das estimativas posteriores de $M \times M$ para M . Desta forma, em vez de estimar $\beta^{(i,j)}_{t/t}$ e $P^{(i,j)}_{t/t}$, ao final de cada iteração teríamos apenas $\beta^j_{t/t}$ e $P^j_{t/t}$. Assim, de forma resumida, o filtro de Kim é dado por uma combinação entre o filtro de Kalman e o filtro de Hamilton, considerando a aproximação das distribuições *a posteriori*, como forma de reduzir o número de equações encontradas a cada passo.

Este filtro pode ser descrito da seguinte forma: o processo de estimação é iniciado em $t=0$ a partir das probabilidades estacionárias $\Pr[S_t = j / \psi_0]$ determinadas no filtro de Hamilton, e dos valores iniciais $\beta^j_{0/0}$ e $P^j_{0/0}$ utilizados para inicializar o filtro de Kalman; a partir de então, o filtro de Kalman é rodado da forma tradicional para os M estados adotados calculando-se:

$$\beta^{(i,j)}_{t/t-1} = \bar{\mu}_j + F_j \beta^i_{t-1/t-1} \quad (1.27)$$

$$P^{(i,j)}_{t/t-1} = F_j P^i_{t-1/t-1} F_j' + Q_j \quad (1.28)$$

$$\eta^{(i,j)}_{t/t-1} = y_t - H_j \beta^{(i,j)}_{t/t-1} \quad (1.29)$$

$$f_{t/t-1}^{(i,j)} = H_j P_{t/t-1}^{(i,j)} H_j' + R_j \quad (1.30)$$

$$\beta_{t/t}^{(i,j)} = \beta_{t/t-1}^{(i,j)} + P_{t/t-1}^{(i,j)} H_j' [f_{t/t-1}^{(i,j)}]^{-1} \eta_{t/t-1}^{(i,j)} \quad (1.31)$$

$$P_{t/t}^{(i,j)} = (I - P_{t/t-1}^{(i,j)} H_j' [f_{t/t-1}^{(i,j)}]^{-1} H_j) P_{t/t-1}^{(i,j)} \quad (1.32)$$

em que $\beta_{t/t-1}^{(i,j)}$ é uma inferência de β_t e $\eta_{t/t-1}^{(i,j)}$ é o erro de previsão condicional de y_t , ambos baseados na informação até o momento $t-1$ dados $S_{t-1}=j$ e $S_{t-1}=i$. Por fim, $f_{t/t-1}^{(i,j)}$ é a variância condicional do erro de previsão $\eta_{t/t-1}^{(i,j)}$, também obtida com base na informação até $t-1$.

Com dois estados, $S_t=1,2$, a cada momento t da iteração seriam produzidos pelo filtro de Kalman os vetores de previsão $\beta_{t/t-1}^{(0,0)}$, $\beta_{t/t-1}^{(0,1)}$, $\beta_{t/t-1}^{(1,0)}$, $\beta_{t/t-1}^{(1,1)}$, $P_{t/t-1}^{(0,0)}$, $P_{t/t-1}^{(0,1)}$, $P_{t/t-1}^{(1,0)}$, $P_{t/t-1}^{(1,1)}$, $\eta_{t/t-1}^{(0,0)}$, $\eta_{t/t-1}^{(0,1)}$, $\eta_{t/t-1}^{(1,0)}$, $\eta_{t/t-1}^{(1,1)}$, $f_{t/t-1}^{(0,0)}$, $f_{t/t-1}^{(0,1)}$, $f_{t/t-1}^{(1,0)}$, $f_{t/t-1}^{(1,1)}$, além dos vetores de atualização $\beta_{t/t}^{(0,0)}$, $\beta_{t/t}^{(0,1)}$, $\beta_{t/t}^{(1,0)}$, $\beta_{t/t}^{(1,1)}$ e $P_{t/t}^{(0,0)}$, $P_{t/t}^{(0,1)}$, $P_{t/t}^{(1,0)}$, $P_{t/t}^{(1,1)}$. Como pode ser visto, um número excessivo de equações são estimadas a cada passo.

O passo seguinte, ainda em $t=1$, é utilizar o filtro de Hamilton para calcular as probabilidades $\Pr[S_t, S_{t-1} / \psi_t]$ e $\Pr[S_t / \psi_t]$ para os M estados. Além disso, como forma de reduzir o número de vetores de previsão é considerada a restrição nas posteriores $\beta_{t/t}^{(i,j)}$ e $P_{t/t}^{(i,j)}$ a partir de uma aproximação da forma

$$\beta_{t/t}^j = \frac{\sum_{i=1}^M \Pr[S_{t-1} = i, S_t = j / \psi_t] \beta_{t/t}^{(i,j)}}{\Pr[S_t = j / \psi_t]}$$

$$P_{t/t}^j = \frac{\sum_{i=1}^M \Pr[S_{t-1} = i, S_t = j / \psi_t] \{P_{t/t}^{(i,j)} + (\beta_{t/t}^j - \beta_{t/t}^{(i,j)})(\beta_{t/t}^j - \beta_{t/t}^{(i,j)})'\}}{\Pr[S_t = j / \psi_t]}$$

Encontrados os valores de $\beta_{t/t}^j$ e $P_{t/t}^j$, passa-se para o momento $t=2$, repetindo o processo até $t=T$. Vale ressaltar que uma vez que o filtro de Hamilton produz uma densidade condicional de y_t , então é possível obter, a cada iteração, a estimativa da função de verossimilhança aproximada, que é dada, no caso da hipótese de normalidade, por:

$$L = \sum_{t=1}^T \ln \sum_{j=1}^M \sum_{i=1}^M \left\{ \frac{2}{\pi^{n/2}} \frac{1}{|Q_t^{(i,j)}|^{1/2}} \exp\left(-\frac{1}{2} \eta_{t/t-1}^{(i,j)} \cdot \frac{1}{Q_t^{(i,j)}} \eta_{t/t-1}^{(i,j)}\right) \right\} \text{Prob}[s_t = j, s_{t-1} = i / \psi_{t-1}] \quad (1.33)$$

Como pode ser visto, os parâmetros do modelo são estimados a partir de um processo de otimização não-linear que maximiza o logaritmo da verossimilhança aproximada em relação aos parâmetros desconhecidos.

Além deste processo de obtenção dos parâmetros pela filtragem, também pode ser feita uma inferência sobre S_t e β_t usando toda a informação na amostra, ou seja, $\text{Pr}[S_t = j / \psi_T]$ e β'_{vT} . Novamente aqui é aplicado o mesmo processo de aproximação feito na filtragem a partir da redução dos termos $\beta^{(i,j)}_{vT}$ e $P^{(i,j)}_{vT}$ para β^j_{vT} e P^j_{vT} . Para mais detalhes sobre a aplicação deste algoritmo, ver Kim (1994) e Kim e Nelson (2000a).

2. RESULTADOS ESTATÍSTICOS

Apesar das dificuldades locais encontradas pelo Estado do Rio Grande do Sul, a sua indústria de transformação conseguiu se desenvolver de maneira bastante diversificada, ocupando hoje o segundo lugar no setor no Brasil, em termos de valor adicionado.

Contudo, este processo de desenvolvimento não ocorreu de forma constante na história econômica do Estado, que não foi contemplado com a primeira grande onda de investimentos estrangeiros que aconteceram no País no pós-guerra. De maneira geral, pode-se dizer que o marco do desenvolvimento da indústria no Rio Grande do Sul remonta ao início dos anos sessenta, com a constituição de uma refinaria de petróleo. Também foi decisiva a política adotada pelo governo federal de priorizar investimentos em infra-estrutura, que posteriormente resultariam na formação de uma sólida indústria de base.

Além disto, o estímulo dado pela União às exportações e à produção de grãos permitiu o crescimento de outros gêneros importantes da indústria de transformação do Estado, como o segmento coureiro-calçadista, que se concentrou na região metropolitana de Porto Alegre, com forte base exportadora, a indústria de produtos alimentares e, posteriormente, o complexo metal-mecânico.

É importante destacar que a constituição de um perfil exportador da indústria local foi um aspecto decisivo neste processo de desenvolvimento, na medida em que criou as

condições para que o setor contornasse as crises econômicas da década de oitenta que limitaram sobremaneira a expansão da demanda agregada interna. A valorização da taxa de câmbio, imposta no início do Plano Real, serviu como um freio a esta continuada expansão da indústria. Este impacto foi significativo em especial nos setores de couros e calçados, por um lado pela redução na competitividade no mercado externo e, por outro, ao expor à concorrência internacional outros setores importantes como o de produtos alimentares. Este cenário perdurou até a mudança de regime cambial de 1999, quando então volta a ganhar ímpeto o setor exportador, influenciando boa parte do desempenho de toda a indústria local.

Atualmente, a matriz industrial do Rio Grande do Sul já se encontra em um alto grau de diversificação e de integração, tendo uma grande importância não apenas para a região como também para o País. Neste sentido, é muito importante que exista um indicador que sirva para monitorar o desempenho deste setor de forma agregada, sinalizando os movimentos cíclicos da indústria no Estado.

Duas instituições já disponibilizam informações sobre o nível de atividade da indústria de transformação local. O IBGE calcula um índice de produção física para a indústria brasileira e desagregado também por Estado da federação. Por outro lado, a Federação das Indústrias do Estado do Rio Grande do Sul (FIERGS) calcula um índice de desempenho industrial (IDI) com base em informações mensais sobre o valor das vendas, compras, salários pagos no setor, horas trabalhadas na produção e a utilização da capacidade instalada. A escolha destas variáveis na composição do IDI segue a metodologia da análise de componentes principais. A partir de então, é feita uma média ponderada destas, considerando um peso específico para cada uma.⁷ As variáveis que compõem o IDI, juntamente com as levantadas pelos demais Estados, são posteriormente utilizadas pela Confederação Nacional da Indústria para produzir os respectivos índices nacionais.⁸

Vale ressaltar que o indicador do IBGE e o calculado pela FIERGS não são concorrentes, mas complementares, na medida em que propõem captar diferentes sinais conjunturais da indústria. De forma geral, o IDI pode ser visto como um indicador coincidente do setor, sendo calculado com base em uma média ponderada entre aquelas cinco variáveis. Por outro lado, o índice do IBGE propõe medir a evolução da quantidade produzida.

O painel de informantes das variáveis observadas pela FIERGS aqui utilizado foi selecionado com base em uma amostra intencional, sendo que o critério para seleção de cada um dos 16 gêneros industriais participantes era o total de empresas que

7 De acordo com a Federação das Indústrias, a Utilização da Capacidade Instalada tem peso de 26,64%, as compras 24,89%, os salários 23,36%, as vendas 22,86% e as horas trabalhadas 2,25%.

8 A Confederação Nacional da Indústria não calcula a variável compras reais.

completassem 50% da mão-de-obra de cada gênero. No caso da indústria de transformação total, este valor mínimo era de 40%. Apesar de alguns gêneros apresentarem problemas de amostra quando analisados de forma desagregada, o total das empresas participantes corresponde a cerca de 43% da mão-de-obra e 38% do valor da transformação industrial do setor.⁹

A proposta deste artigo é confrontar a metodologia utilizada pela FIERGS com o modelo de fator dinâmico proposto por Stock e Watson. Esta comparação será feita considerando tanto a sua forma linear quanto a não-linear apresentadas na seção anterior. Com isto, será possível produzir um indicador composto para o Estado que além de representar a dinâmica do setor industrial também caracterize o ciclo dos negócios no setor.

As séries a serem utilizadas são as mesmas que a Federação das Indústrias do Estado do Rio Grande do Sul utiliza para calcular seu índice. A periodicidade é mensal, sendo representadas por um índice de base fixa desazonalizado,¹⁰ que compreende o período janeiro de 1992 a março de 2003, com um total de 135 observações.

É importante destacar aqui que o pequeno período amostral disponível reduz sensivelmente os graus de liberdade do modelo e não permite que se tenha a formação de uma grande quantidade de períodos de recessão e de crescimento para a economia.¹¹ Os Gráficos 2.1 a 2.5 mostram o comportamento de cada uma destas variáveis ao longo desse período.

Como pode ser observado, tanto a série das vendas como a de compras industriais mostram evidência de uma tendência de crescimento consistente ao longo de toda a década de noventa. As maiores quedas na atividade setorial para ambas as séries podem ser verificadas nos seis meses após a implementação do Plano Real e no segundo semestre de 2001. No primeiro caso têm-se, principalmente, os efeitos da apreciação cambial sobre o setor exportador do Estado. No segundo caso, a redução verificada no final de 2001 esteve associada à piora no cenário econômico internacional, principalmente após os atentados terroristas ocorridos nos Estados Unidos. O resultado foi um impacto significativo não só nas transações comerciais do Brasil e do Estado com o exterior como também a atividade industrial no mercado interno.

9 Um dos problemas que ocorrem quando se faz pesquisas como a elaborada pelos indicadores industriais da FIERGS é que, devido ao fechamento e abertura de empresas ao longo do período de análise, o painel de informantes pode variar. Porém, a formação do indicador leva em conta a representação estatística agregada, e não a comparação entre os participantes da amostra.

10 Foi utilizado o método da razão das médias móveis – multiplicativo.

11 Esta mesma dificuldade foi encontrada por Spacov (2001).

GRÁFICO 2.1 – VENDAS REAIS




GRÁFICO 2.2 – COMPRAS REAIS




GRÁFICO 2.3 – SALÁRIOS TOTAIS




GRÁFICO 2.4 – HORAS TRABALHADAS




GRÁFICO 2.5 – UTILIZAÇÃO DA CAPACIDADE INSTALADA





GRÁFICO 2.6 – ÍNDICE DE DESEMPENHO INDUSTRIAL



Por outro lado, as variáveis relacionadas com o mercado de trabalho na indústria de transformação do Estado apresentam um comportamento um pouco diferente. No início do Plano Real, a rápida queda da inflação resultou em um enorme ganho de renda para os trabalhadores no setor. Contudo, à medida que a atividade industrial

se estabilizou, os salários apresentaram um comportamento estável, começando a apresentar queda a partir de 1998. Mesmo com o pequeno repique inflacionário que foi verificado após a mudança de regime cambial, os salários no setor tiveram ganhos reais, seguindo o desempenho de outras variáveis como as vendas e as compras. É importante destacar que aquele ano também resultou em uma interrupção da queda nas horas trabalhadas na indústria que se fazia presente desde o início do Plano Real.

Já a variável utilização da capacidade instalada mostra uma pequena oscilação durante o período analisado. Nota-se que após iniciar a década de noventa sob os efeitos negativos do Plano Collor, os períodos de maior ociosidade na indústria foram verificados nos primeiros meses pós Plano Real, com 76% de utilização, e no início de 2003, com 78%. Por fim, tem-se, no Gráfico 2.6, o comportamento do IDI, que também sinaliza no pós Plano Real e no último semestre de 2001 uma forte queda da atividade econômica da indústria de transformação do Estado.

2.1 Modelo Linear

O primeiro passo para a especificação do modelo de fator dinâmico linear é verificar a existência de raiz unitária nestas séries. Para tanto, foi utilizado o teste ADF para vários *lags*, e seus resultados encontram-se na Tabela 1 do anexo. Como pode ser visto, todas as séries, à exceção da utilização da capacidade instalada, são estacionárias a partir da primeira diferença. Porém, tal como relatado anteriormente, e como mostrado nos gráficos acima, durante o período aqui analisado estas variáveis apresentaram diversas quebras estruturais, que ocorreram tanto no intercepto quanto na taxa de crescimento.

Desta forma, o teste mais apropriado para verificar a existência de raiz unitária na presença de quebra estrutural é o de Perron (1997), e seus resultados, apresentados na Tabela 2 do anexo, confirmam a evidência de raiz unitária, mesmo para a série da utilização da capacidade. O processo de seleção do VAR nos conduz a um modelo com uma defasagem, e a inspeção da relação de co-integração pelo teste de Johansen revela a existência de apenas um vetor de co-integração.

O próximo passo é a formulação de um modelo de fator dinâmico linear considerando a diferença no logaritmo das séries, de forma a torná-las estacionárias, nos moldes do proposto por Stock e Watson. Vale ressaltar que aqui são utilizadas cinco variáveis tal qual o formato apresentado nas matrizes (1.9) e (1.10). Inicialmente foram estimados dois modelos. O primeiro é dado por $p=2$ e $r=2$ na equação (1.3) e (1.8), ou seja, com duas defasagens para o componente idiossincrático (Δu_{it}) e para o comum (Δc), e o segundo, que considera $p=2$ e $r=1$. Na primeira formulação, o valor do logaritmo da

verossimilhança obtido foi 1852,581, enquanto que na segunda tem-se um valor de 1852,441. Assim, pelo teste LR, com $\chi^2_{(1)} = 0,59$, não é possível rejeitar a hipótese de duas defasagens para o componente comum.

Aplicando o filtro de Kalman em conjunto com o processo de maximização numérica da função de verossimilhança, os parâmetros desconhecidos do modelo de índice único podem ser estimados (ver Harvey, 1989 e Kim e Nelson, 2000a). A Tabela 2.1 apresenta os resultados do modelo linear.

À exceção dos coeficientes d_{12} , d_{41} e d_{42} , todos os demais são significativos, e o valor negativo obtido para d_{11} e d_{12} revela que o componente idiossincrático destas séries apresenta uma autocorrelação negativa. Outro ponto a destacar é o alto valor de $\gamma_{compras}$ e γ_{vendas} , indicando que estas duas variáveis possuem alta sensibilidade em relação ao ciclo dos negócios, respondendo de forma imediata a modificações no cenário econômico.

Uma comparação entre os pesos utilizados na construção da taxa de crescimento de c_{it} e do IDI pode fornecer uma indicação do comportamento destes dois indicadores. Como pode ser visto na Tabela 2.2, em que os pesos de c_{it} foram normalizados para somar um, a variável compras tem peso de 35% e a de vendas 32%. Estes valores contrastam com os calculados pelo IDI, em que o peso das compras é de 24% e das vendas 22%. Porém, a maior diferença encontrada entre estes dois indicadores foi o peso da utilização da capacidade e dos salários.¹²

TABELA 2.1 – ESTIMATIVA DOS PARÂMETROS (Modelo Stock e Watson Linear)

Parâmetros	Coefficientes	Desvio padrão	Parâmetros	Coefficientes	Desvio padrão
ϕ_1	-0,5411	0,1123	d_{52}	-0,0388	0,0184
ϕ_2	-0,0732	0,0303	σ_{vendas}	16,603	2,9125
d_{11}	-0,363	0,1135	$\sigma_{compras}$	19,857	3,7185
d_{12}	-0,0329	0,0206	$\sigma_{salário}$	5,2953	0,6867
d_{21}	-0,4241	0,1110	σ_{horas}	6,9634	1,3554
d_{22}	-0,0449	0,0235	σ_{uci}	1,5685	0,2027
d_{31}	-0,3001	0,0851	γ_{vendas}	4,0003	0,4969
d_{32}	0,0088	0,0000	$\gamma_{compras}$	4,4109	0,5739
d_{41}	-0,1203	0,1279	$\gamma_{salário}$	0,9567	0,2310
d_{42}	-0,0036	0,0077	γ_{horas}	2,6517	0,3295
d_{51}	-0,3942	0,0935	γ_{uci}	0,4666	0,1322

Nota: Os desvios padrão são os elementos da diagonal da inversa do hessiano obtido da otimização numérica.

12 É importante lembrar que o indicador calculado pela FIERGS a partir das médias ponderadas utiliza a análise dos componentes principais para determinar os pesos para cada variável.

TABELA 2.2 – PESOS DAS VARIÁVEIS QUE COMPÕEM C_{TT} E O IDI

	Vendas	Compras	Salários	Horas	Uci
Componente comum	0,3204	0,3533	0,0766	0,2124	0,0374
IDI	0,2286	0,2489	0,2336	0,0225	0,2664

Após a estimativa destes parâmetros, o filtro de Kalman pode ser rodado novamente para obter-se $\Delta c_{t/t}$ e, em seguida, a média de Δc_t , que é dada por δ . Por fim, a partir de

$$C_{t/t} = C_{t/t-1} + \Delta c_{t/t} + \delta$$

pode-se calcular o índice coincidente. A evolução do índice proposto, comparativamente ao IDI e a cada uma de suas variáveis utilizadas, é mostrada nos Gráficos 2.7 a 2.12.

Apesar de o indicador coincidente estimado ter apresentado peso diferente entre as variáveis, a sua dinâmica é muito próxima ao IDI, captando os movimentos de queda e crescimento na atividade ao longo do período amostral. Para facilitar a comparação, no Gráfico 3.12 foram utilizados dois eixos, um para o indicador coincidente, expresso em índice, e outro para a utilização da capacidade instalada, expressa em porcentual.

GRÁFICO 2.7 – COMPONENTE COMUM E IDI




GRÁFICO 2.8 – COMPONENTE COMUM E VENDAS

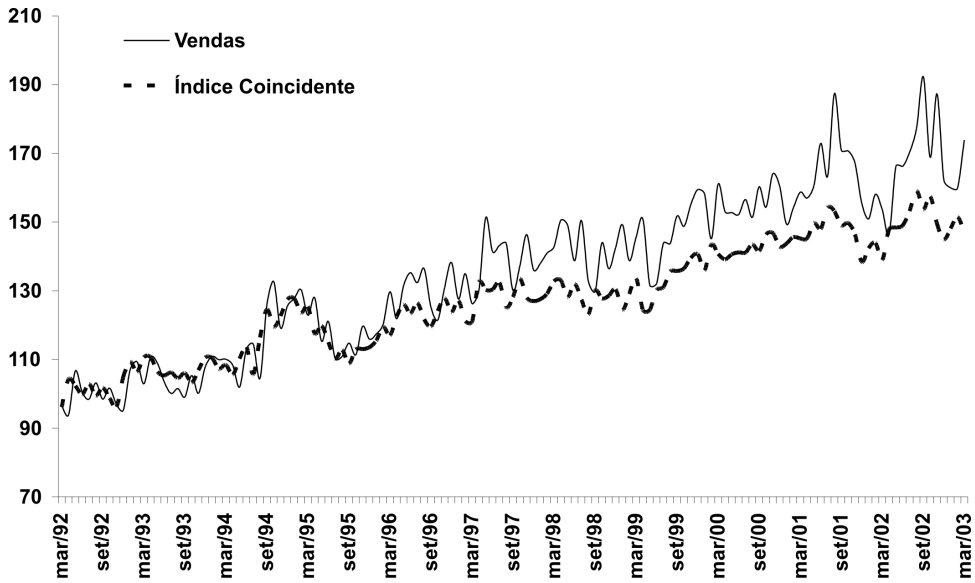


GRÁFICO 2.9 – COMPONENTE COMUM E COMPRAS




GRÁFICO 2.10 – COMPONENTE COMUM E SALÁRIOS




GRÁFICO 2.11 – COMPONENTE COMUM E HORAS TRABALHADAS


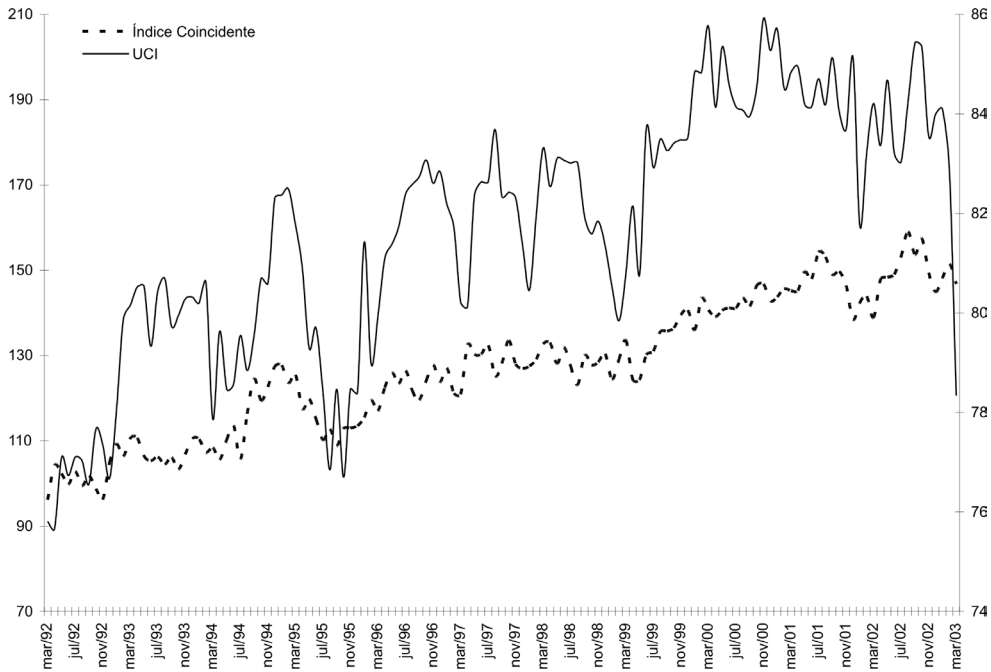


GRÁFICO 2.12 – COMPONENTE COMUM E UCI



A Tabela 2.3 compara o desvio padrão do indicador estimado com o IDI e todas as outras variáveis. Nota-se que aquele é bem menor para $c_{t/t}$ do que para o IDI. Pelos dados de correlação em nível há uma boa adaptação do indicador proposto com o calculado pela FIERGS e as variáveis vendas e compras. Note a correlação negativa entre o indicador comum e a variável horas trabalhadas. Este resultado é muito influenciado pelo comportamento desta variável *vis-à-vis* às demais no período compreendido entre 1995 e 1999.

TABELA 2.3 – CARACTERÍSTICAS DO INDICADOR COINCIDENTE E SUAS VARIÁVEIS

	$C_{t/t}$	IDI	Vendas	Compras	Salários	Horas	Uci
Desvio-Padrão	15,79	19,74	23,15	30,13	11,28	7,43	2,45
Correlação com $C_{t/t}$		0,99	0,98	0,91	0,74	-0,32	0,86
Correlação com $\Delta C_{t/t}$		0,92	0,90	0,70	0,36	0,68	0,38

Uma regra de bolso que pode ser utilizada para caracterizar o ciclo dos negócios é que dois trimestres seguidos de queda da atividade econômica configurariam uma recessão

(ver Chauvet, 2002). A Tabela 2.4 mostra as possíveis datas em que a indústria de transformação do Rio Grande do Sul poderia estar em recessão a partir deste critério. Note que, à exceção da indicação para 1993, todas as demais datas coincidem.

TABELA 2.4 – DATAS DE RECESSÃO NA INDÚSTRIA DE TRANSFORMAÇÃO DO RIO GRANDE DO SUL

IDI	1992/IV	1993/IV	1995/III	2002/I	2003/I
c_{it}	1992/IV	1993/III	1995/III	2002/I	2003/I

2.2 Modelo com Mudança de Regime

A seguir é feita a estimativa do modelo de fator dinâmico não-linear com o intuito de não apenas verificar se existe assimetria no ciclo dos negócios na indústria de transformação do Rio Grande do Sul, mas também para datar estes períodos com base em um critério estatístico. É assumido aqui que a variável de mudança de regime segue uma cadeia de Markov de dois estados, com a equação de medida dada por (1.21) e a de transição dada por $\beta_t = \mu_{s_t} + F\beta_{t-1} + v_t$, não sendo utilizada a equação (1.22).¹³

Desta forma, em cada iteração do filtro de Kalman são obtidas estimativas de 2² estados, e aplicando o algoritmo de Kim (1994) podem ser encontrados os parâmetros do modelo. É assumido ainda que o componente comum e o idiossincrático têm duas defasagens, facilitando a sua comparação com a formulação linear estimada anteriormente.

Contudo, diferentemente dos resultados antes obtidos, quando é incorporada a mudança de regime, o modelo não parece ser robusto. Vale dizer que as estimativas finais são muito mais sensíveis ao valor determinado para os parâmetros iniciais.¹⁴ Desta forma, para uma mesma formulação foram tentados diferentes valores iniciais para os parâmetros. A escolha do modelo final recaiu sobre aquele que apresentasse o maior valor do logaritmo da verossimilhança. A Tabela 2.5. mostra os resultados para a estimativa não-linear.

¹³ Ver Kim e Yoo (1995).

¹⁴ Isso ocorreu com maior intensidade nos parâmetros σ_i . Porém, para parâmetros σ muito grandes, os resultados passaram a ser os mesmos.

TABELA 2.5 – ESTIMATIVA DOS PARÂMETROS (MODELO STOCK E WATSON COM MUDANÇA DE REGIME)

Parâmetros	Coefficientes	Desvio padrão	Parâmetros	Coefficientes	Desvio padrão
ϕ_1	-0,541	0,111	$\sigma_{compras}$	4,456	0,419
ϕ_2	-0,073	0,030	$\sigma_{salário}$	2,301	0,149
d_{11}	-0,363	0,113	σ_{horas}	2,638	0,257
d_{12}	-0,032	0,020	σ_{uci}	1,252	0,081
d_{21}	-0,424	0,111	γ_{vendas}	4,000	0,495
d_{22}	-0,044	0,023	$\gamma_{compras}$	4,410	0,577
d_{31}	-0,300	0,084	$\gamma_{salário}$	0,956	0,229
d_{32}	0,0088	0,000	γ_{horas}	2,652	0,328
d_{41}	-0,120	0,128	γ_{uci}	0,466	0,133
d_{42}	-0,003	0,007	μ_0	0,001	0,022
d_{51}	-0,394	0,093	μ_1	0,001	0,000
d_{52}	-0,038	0,018	p	0,807	0,000
σ_{vendas}	4,074	0,358	q	0,547	0,000

Nota: Os desvios padrão são os elementos da diagonal da inversa do hessiano obtido da otimização numérica.

À exceção dos parâmetros d_{12} , d_{41} , d_{42} e μ_0 , todos os demais coeficientes são significativos.¹⁵ Também é possível ver que as variâncias são maiores no modelo linear. A Tabela 3.6 mostra os pesos e a correlação existente entre c_{it} , o IDI e as demais variáveis. O peso de todas as variáveis é muito próximo do encontrado no modelo anterior, sendo que a variável utilização da capacidade instalada continua a ter o menor peso. Outro ponto a destacar é que a correlação encontrada entre o componente comum e o IDI e todas as demais variáveis é maior no modelo linear do que a calculada no modelo com mudança de regime. Novamente, as horas trabalhadas mostram ser um componente contracíclico na indústria de transformação do Rio Grande do Sul.

TABELA 2.6 – VARIÁVEIS QUE COMPÕEM C_{TT} E O IDI

	IDI	Vendas	Compras	Salários	Horas	Uci
Componente comum (Pesos)	-	0,320	0,353	0,076	0,212	0,037
Correlação com C_{it}	0,98	0,95	0,86	0,73	-0,46	0,82
Correlação com ΔC_{it}	0,84	-0,41	-0,19	-0,18	-0,39	-0,18

O Gráfico 2.13 mostra o comportamento do componente comum aqui estimado e o IDI, e o Gráfico 2.14 compara o indicador proposto no modelo não-linear com

¹⁵ Note que os parâmetros d_{12} , d_{41} , d_{42} também não foram significativos no modelo linear.

aquele e o estimado de forma linear.¹⁶ Apesar de ambos mostrarem estreita relação entre os indicadores, o desvio padrão do componente comum estimado pelo modelo não-linear é maior do que o do modelo linear: 20,61 e 15,79 respectivamente.

GRÁFICO 2.13 – COMPONENTE COMUM E IDI


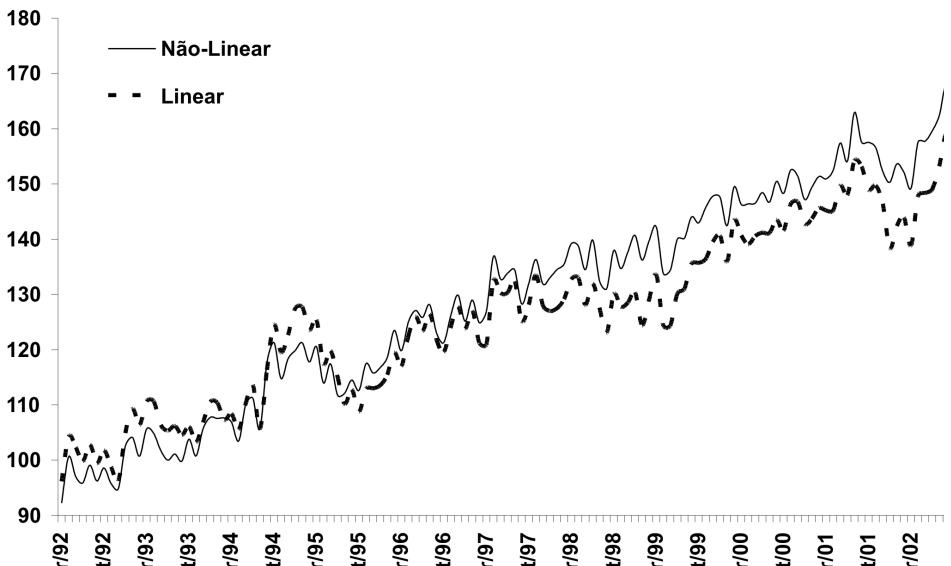


GRÁFICO 2.14 – COMPONENTE COMUM LINEAR E NÃO-LINEAR



16 O teste de co-integração feito entre o componente comum não-linear e o IDI, mostrado na Tabela 7 do anexo, revela a presença de um vetor de co-integração. Já quando feito o teste entre o componente estimado na forma linear com o encontrado na formulação não-linear, rejeita-se a hipótese de co-integração, como pode ser visto na Tabela 8 do anexo.

A matriz de transição dos regimes estimada é dada por:

$$P = \begin{vmatrix} 0,547 & 0,443 \\ 0,193 & 0,807 \end{vmatrix}$$

Analisando os valores de q , a probabilidade de se estar em $t-1$ em uma fase de crescimento e continuar em t , e p , a probabilidade de em $t-1$ a indústria ter apresentado queda na atividade e continuar apresentando em t , nota-se que a duração média do período de crescimento é muito menor do que a duração da queda: 2,21 e 5,18 meses.

Os Gráficos 2.15 e 2.16 mostram as probabilidades suavizadas de crescimento e queda na atividade econômica na indústria gaúcha durante a última década. Vale ressaltar que o critério aqui utilizado para classificar se a indústria está em um ciclo de expansão é dado por $Pr(S_t = 1) > 0,5$, como pode ser visto pela linha horizontal que serve para dividir estes períodos.

GRÁFICO 2.15 – PROBABILIDADE SUAVIZADA DE CRESCIMENTO





GRÁFICO 2.16 – PROBABILIDADE SUAVIZADA DE QUEDA



A comparação dos períodos do ciclo econômico no modelo não-linear com o estimado para o caso linear fica prejudicada porque enquanto aqui estes períodos foram obtidos com base em informações mensais, no modelo linear estes foram calculados a partir de um comportamento trimestral.

Dois aspectos devem ser considerados em relação à alta volatilidade dos resultados não-lineares aqui encontrados: os choques transitórios e permanentes que atingiram a economia brasileira nos últimos vinte anos e que produziram um comportamento muito volátil para a produção, dificultando a mensuração do ciclo no Brasil. E, mesmo que a periodicidade trimestral possa elucidar acerca do comportamento cíclico da economia, o mais indicado é que se disponha de dados anuais e por um período longo de tempo.

CONCLUSÃO

Este artigo aplica a metodologia de Stock e Watson para construir um índice de indicadores coincidentes para a indústria de transformação do Estado do Rio Grande do Sul com base nas variáveis vendas reais, compras reais, salários líquidos reais, horas trabalhadas na produção e utilização da capacidade instalada. Além do modelo linear, também foi investigada a possibilidade deste índice apresentar um compor-

tamento não-linear devido à existência de diferentes regimes com a incorporação de uma variável de estado não observada. As estimativas dos parâmetros foram feitas, neste caso, a partir do algoritmo proposto por Kim (1994).

Inicialmente, foram testadas duas formulações para o modelo linear que contemplassem uma e duas defasagens para o componente comum. Pelo teste de razão de verossimilhança é selecionado o modelo com duas defasagens. As maiores diferenças entre os resultados encontrados a partir da metodologia de Stock e Watson e o IDI estão relacionadas ao peso de cada variável, com destaque para o maior peso das compras e vendas e ao menor peso para a variável Uci no indicador composto comparativamente ao IDI. Apesar desta diferença nos pesos, existe uma alta correlação entre o novo indicador e todas as demais variáveis. Uma das formas de se datar o ciclo dos negócios é utilizar como regra de bolso dois trimestres consecutivos de queda da atividade econômica. Neste caso, os resultados para o IDI e o indicador proposto em relação às datas de recessão na indústria de transformação do Estado são equivalentes.

Os coeficientes estimados a partir do modelo não-linear tiveram valores bem próximos ao do modelo linear, à exceção dos parâmetros que medem o desvio padrão das variáveis, tendo estes sido menores quando se incorpora a mudança de regime. Também no modelo não-linear os pesos das variáveis ficaram próximos do estimado da forma linear. Vale ressaltar que enquanto a correlação, quando medida em nível, é menor no modelo com mudança de regime, comparativamente à obtida no modelo linear, o mesmo não se verifica na correlação a partir da taxa de crescimento. A estimativa das probabilidades de transição mostra que a probabilidade de a indústria estar em queda em $t-1$ e continuar em queda em t é maior do que estar em crescimento em $t-1$ e continuar em crescimento em t . A duração estimada de cada regime foi de 2,21 meses para o crescimento e de 5,18 para queda na atividade industrial.

REFERÊNCIAS

- Burns, A.; Mitchell, W. *Measuring business cycles*. New York: National Bureau of Economic Research, 1946.
- Chauvet, M., An econometric characterization of business cycle dynamics with factor structure and regime switching. *International Economic Review*, v. 39, n. 4, p. 969-96, 1998.
- _____. The Brazilian business and growth cycles. *RBE*, v. 56, n. 1, p. 75-106, 2002.
- Dempster, A. P.; Laird, N. M.; Rubin, D. B. Maximum likelihood from incomplete data via the EM algorithm. *Journal of Royal Statistical Society*, B 39, p. 1-38, 1977.

- Diebold, F. X.; Rudebusch, G. D. Measuring business cycles: a modern perspective. *Review of Economics and Statistics*, 78, p. 67-77, 1996.
- Dijk, D. V. *Extensions and outlier robust inference*. Tinberger Institute Research series 200, Rotterdam: Erasmus University, 1999.
- Engel, C.; Hamilton, J. D. Long swings in the dollar: are they in the data and do markets know it? *American Economic Review*, 80, p. 689-713, 1990.
- Engle, R. F.; Issler, J. V. Common trends and common cycles in Latin America. *Revista Brasileira de Economia*, v. 47, n. 2, p. 149-176, 1993.
- _____. Estimating common sectoral cycles. *Journal of Monetary Economics*, 35, p. 83-113, 1995.
- Filardo, A. Business cycle phases and their transitional dynamics. *Journal of Business and Economic Statistics*, 12, p. 299-308, 1994.
- _____. How reliable are recession prediction models. *FED Kansas City Economic Review*, 2nd. Quarter, p. 35-55, 1999.
- Forni, M.; Hallin, M.; Lippi, M.; Reichlin, L. Coincident and leading indicators for the EURO area. *Working Paper*, 2000a.
- _____. The Generalized dynamic factor model: identification and estimation. *The Review of Economics and Statistics*, v. 82, n. 4, p. 540-554, 2000b.
- Granger, C. W. J.; Teräsvirta, T. *Modelling nonlinear economic relationships*. Oxford: Oxford University Press, 1993.
- Hamilton, J. D. A new approach to the economic analysis of nonstationary time series and the business cycle. *Econometrica*, v. 57, p. 357-384, 1989.
- _____. Analysis of time series subject to changes in regime. *Journal of Econometrics*, v. 45, p. 39-70, 1990.
- _____. A quasi-Bayesian approach to estimating parameters for mixtures of normal distributions. *Journal of Business and Economic Statistics*, 9, p. 27-39, 1991.
- _____. Specification testing in Markov-Switching time series models. *Journal of Econometrics*, 70, p. 127-157, 1996.
- Hamilton, J. D.; Susmel, R. Autoregressive conditional heteroskedasticity and changes in regime. *Journal of Econometrics*, 64, p. 307-333, 1994.
- Hansen, B. E. The likelihood ratio test under non-standard conditions: testing the Markov switching model of GNP. *Journal of Applied Econometrics*, 7, S61-S82, 1992.
- Harvey, A. C. *Forecasting, structural time series models and the Kalman Filter*. Cambridge: Cambridge University Press, 1989.
- Hylleberg, S.; Engle, R. F.; Granger, C. W. J.; Yoo, B.S. Seasonal integration and cointegration. *Journal of Econometrics*, 44, p. 215-238, 1990.

- Issler, J.V.; Vahid, F. Common cycles and the importance of transitory shocks to macroeconomic aggregates. *Ensaos Econômicos*, Fundação Getúlio Vargas, n. 334, 1998. (A sair no *Journal of Monetary Economics*).
- _____. *The missing link*: using common cycles to construct an index of coincident and leading indicators of economic activity. Fundação Getúlio Vargas, 2000. Mimeografado.
- Kholodilin, K. A. Unobserved leading and coincident common factors in the post-war U.S. business cycle. *Working Paper*, 2002.
- Kim, C-J., Dynamic linear models with Markov-switching. *Journal of Econometrics*, 60, p. 1-22, 1994.
- Kim, C-J.; Nelson, C. R. Business cycle turning points: a new coincident index, and tests of duration dependence based on a dynamic factor model with regime-switching. *Review of Economics and Statistics*, 80, p. 188-201, 1998.
- _____. State-space models with regime switching. 2nd edition. MIT Press, 2000.
- Kim, C-J.; Piger, J. Common stochastic trends, common cycles, and asymmetry in economic fluctuations. *International Finance Discussion Papers*, n. 681, 2000.
- Kim, C-J.; Yoo, J-S. New index of coincident indicators: a multivariate Markov switching factor model approach. *Journal of Monetary Economics*, 36, p. 607-630, 1995.
- Krolzig, H-M. Statistical analysis of cointegrated VAR processes with Markovian regime shifts. SFB 373, *Discussion Paper*, 25, Humboldt Universität zu Berlin, 1996.
- _____. Markov switching vectors autoregressions modelling, statistical inference and application to business cycle analysis. Berlin: Springer, 1997.
- Lam, P-S. The Hamilton model with a general autoregressive component. Estimation and comparison with other models of economic time series. *Journal of Monetary Economics*, 26, p. 409-432, 1990.
- Lütkepohl, H.; Saikkonen, P. Impulse response analysis in infinite order cointegrated vector autoregressive processes. Humboldt Universität zu Berlin, SFB 373, *Discussion Paper* 11, 1995.
- Nieto, F.H.; Melo, L.F. About a coincident index for the state of the economy. *Working Paper*, 2001.
- Perron, P. Further evidence on breaking trend functions in macroeconomic variables. *Journal of Econometrics*, v. 80, p. 355-385, 1997.
- Phillips, K. L. A two-country model of stochastic output with changes in regime. *Journal of International Economics*, 31, p. 121-142, 1991.
- Picchetti, P.; Toledo, C. Estimating and interpreting a common stochastic component for the Brazilian industrial production index. *Revista Brasileira de Economia*, v. 56, n. 1, p. 107-120, 2002.

- Portugal, M. S. As políticas brasileiras de comércio exterior – 1947-88. *Ensaio FEE*, Porto Alegre, v. 1, n. 15, p. 234-252, 1994.
- Ruud, P.A. Extension of estimation methods using the EM-algorithm. *Journal of Econometrics*, 49, p. 305-341, 1991.
- Saikkonen, P. Estimation and testing of cointegrated systems by an autoregressive approximation. *Econometric Theory*, 8, p. 1-27, 1992.
- Spacov, A. D. *Índices antecedentes e coincidentes da atividade econômica brasileira: uma aplicação da análise de correlação canônica*. 2001. Dissertação (Mestrado), Escola de Pós-Graduação em Economia – Fundação Getúlio Vargas.
- Stock, J. H.; Watson, M. H. A new approach to leading economic indicators. *Working Paper*, Haward University, Kennedy School of Government, 1988.
- _____. New indexes of coincident and leading economic indicators. In: Blanchard, O.; Fischer, S. (eds.), *NBER macroeconomics annual*. Cambridge: MIT Press, 1989. p.351-394.
- _____. A probability model of the coincident economic indicators. In: Lahiri, K.; Moore, G. H. (eds.), *Leading economic indicator: new approaches and forecasting records*. Cambridge: Cambridge University Press, 1991. p. 63-89.
- _____. A procedure for predicting recessions with leading indicators: econometric issues and recent experience. In: Stock, J. H.; Watson, M. W. (eds.), *Business cycles, indicators and forecasting*. Chicago: University of Chicago Press for NBER, 1993. p. 255-284.
- Teräsvirta, T.; Anderson, H. Characterising nonlinearities in business cycles using smooth transition autoregressive models. *Journal of Applied Econometrics*, S119-S136, 1992.
- Tsay, R. S. Testing and modelling threshold autoregressive process. *Journal of the American Statistical Association*, 84, p. 231-240, 1989.
- _____. Testing and modeling multivariate threshold models. *Journal of American Statistical Association*, 93, p. 1188-1202, 1998.
- Vahid, F.; Engle, R. F. Common trends and common cycles. *Journal of Applied Econometrics*, v. 8, p. 341-360, 1993.

ANEXO 1 (RESULTADOS)

TABELA 1 – TESTE DE RAIZ UNITÁRIA EM NÍVEL E DIFERENÇAS

	Em nível					Em diferenças			
	τ	τ_{μ}	τ_{τ}	I(.)		τ	τ_{μ}	τ_{τ}	I(.)
Vendas	3,250	-1,046	-2,726	I(1)	Δ Vendas	-4,157 ^a	-6,548 ^a	-6,607 ^a	I(0)
Compras	2,091	-0,027	-2,054	I(1)	Δ Compras	-5,203 ^a	-5,141 ^a	-5,145 ^a	I(0)
Salário	1,043	-2,475	-1,595	I(1)	Δ salário	-15,434 ^a	-15,483 ^a	-15,741 ^a	I(0)
Horas	-0,229	-1,497	-0,325	I(1)	Δ Horas	-2,289 ^a	-3,791 ^a	-4,456 ^a	I(0)
Uci	0,534	-2,633 ^c	-3,339 ^c	I(1)	Δ Uci	-16,083 ^a	-16,047 ^a	-16,122 ^a	I(0)

Nota: τ é sem constante, τ_{μ} é o teste com constante e τ_{τ} é o teste com constante e com tendência. I(.) é a ordem de integração. Rejeita a 1%, b 5% e c acima de 10%.

TABELA 2 – TESTE DE RAIZ UNITÁRIA NA PRESENÇA DE QUEBRA ESTRUTURAL

Teste	Modelo	Vendas	Compras	Salário	Horas	Uci
UR	1	-4,319	-4,674	-4,357	-1,913	-4,298
	2	-4,259	-4,851	-4,438	-3,471	-4,746
	3	-3,972	-4,071	-2,975	-2,517	-4,433
STUD	1	-4,319	-4,674	-4,116	-1,611	-4,002
	2	-4,004	-4,150	-2,325	-3,436	-4,418
	3	-3,959	-4,012	-2,788	-2,515	-4,121
STUDABS	1	-4,319	-4,674	-4,116	-1,611	-4,001
	2	-4,004	-4,150	-2,325	-3,436	-4,419
	3	-3,959	-4,012	-2,788	-2,515	-4,122

TABELA 3 – SELEÇÃO DO LAG DO VAR

Variáveis	Ordem	Akaike	Schwarz
Vendas	1	1391,20	1391,85
Compras	2	1422,22	1423,43
Salário	3	1429,76	1431,51
Horas	4	1432,62	1432,94
Uci	5	1444,89	1447,78
	6	1458,61	1462,07
	7	1476,28	1480,31
	8	1489,40	1494,02
	9	1498,50	1503,71
	10	1513,37	1519,17
	11	1527,23	1533,63
	12	1556,35	1563,36

TABELA 4 – TESTE DE CO-INTEGRAÇÃO DE JOHANSEN(1988)

Autovalor	0,250	0,137	0,084	0,055	0,006
Teste LR	78,29	39,89	20,19	8,44	0,86
Valor Crítico a 5%	68,52	47,21	29,68	15,41	3,76
Valor Crítico a 1%	76,07	54,46	35,65	20,04	6,65
H ₀ : Posto = r	r = 0	r ≤ 1	r ≤ 2	r ≤ 3	r ≤ 4

Nota: o teste LR indica a presença de 1 vetor de co-integração a 5%.

TABELA 5 – TESTE DE CO-INTEGRAÇÃO DE JOHANSEN (1988)
COMPONENTE COMUM LINEAR E NÃO-LINEAR E IDI

Autovalor	0,1356	0,0737	0,0034
Teste LR	29,365	10,411	0,451
Valor Crítico a 5%	29,68	15,41	3,76
Valor Crítico a 1%	35,65	20,04	6,65
H ₀ : Posto = r	r = 0	r ≤ 1	r ≤ 2

Nota: o teste LR rejeita a hipótese de qualquer vetor de co-integração a 5%.

TABELA 6 – TESTE DE CO-INTEGRAÇÃO DE JOHANSEN (1988)
COMPONENTE COMUM LINEAR E IDI

Autovalor	0,1585	0,0031
Teste LR	22,859	0,416
Valor Crítico a 5%	15,41	3,76
Valor Crítico a 1%	20,04	6,65
H ₀ : Posto = r	r = 0	r ≤ 1

Nota: o teste LR rejeita a hipótese de qualquer vetor de co-integração a 5%. O teste LR indica a presença de apenas 1 vetor de co-integração a 5%.

TABELA 7 – TESTE DE CO-INTEGRAÇÃO DE JOHANSEN (1988)
COMPONENTE COMUM LINEAR E NÃO-LINEAR E IDI

Autovalor	0,1581	0,0050
Teste LR	23,20	0,6609
Valor Crítico a 5%	15,41	3,76
Valor Crítico a 1%	20,04	6,65
H ₀ : Posto = r	r = 0	r ≤ 1

Nota: o teste LR indica a presença de 1 vetor de co-integração a 5%.

**TABELA 8 – TESTE DE CO-INTEGRAÇÃO DE JOHANSEN (1988)
COMPONENTE COMUM LINEAR E NÃO-LINEAR**

Autovalor	0,0786	0,004
Teste LR	11,174	0,522
Valor Crítico a 5%	15,41	3,76
Valor Crítico a 1%	20,04	6,65
H_0 : Posto = r	r = 0	r ≤ 1

Nota: o teste LR rejeita a hipótese de qualquer vetor de co-integração a 5%.

ANEXO 2 (FONTE E DESCRIÇÃO DOS DADOS)

Vendas – Índice de base fixa mensal (1992=100) das vendas reais da indústria de transformação do Estado do Rio Grande do Sul. Fonte: FIERGS.

Compras – Índice de base fixa mensal (1992 = 100) das compras reais da indústria de transformação do Estado do Rio Grande do Sul. Fonte: FIERGS.

Horas – Índice de base fixa mensal (1992=100) das horas trabalhadas na produção na indústria de transformação do Estado do Rio Grande do Sul. Fonte: FIERGS.

Salários – Índice de base fixa mensal (1992=100) dos salários líquidos reais totais da indústria de transformação do Estado do Rio Grande do Sul. Fonte: FIERGS.

Uci – Utilização da Capacidade Instalada da indústria de transformação do Estado do Rio Grande do Sul. Fonte: FIERGS.

IDI – Índice de Desempenho Industrial, base fixa mensal (1992=100). Construído a partir de uma média ponderada das variáveis vendas, compras, salários, horas e utilização da capacidade. Fonte: FIERGS.