

IDENTIFICAÇÃO DE PARÂMETROS EM MODELOS ECONÓMICOS DINÂMICOS*

Nikolay Iskrev**

1. INTRODUÇÃO

A identificação de parâmetros é um conceito que cada aluno de economia aprende em econometria. O tratamento usual da identificação leva a pensar na identificação como uma questão técnica relevante apenas para o trabalho empírico, e considera os problemas de identificação como causados por deficiências nos dados disponíveis, ou da metodologia estatística utilizada para estimar os modelos. Neste artigo argumenta-se que a análise de identificação tem um aspeto de modelização económica importante, e que pode ser muito útil para investigadores que não estão interessados na estimação. A discussão centra-se no caso de modelos de equilíbrio geral dinâmico estocástico (DSGE) que se tornaram uma das principais ferramentas de análise de macroeconomia moderna. A essência do argumento é que, quando o modelo económico fornece uma caracterização completa do processo de geração de dados, a identificação dos parâmetros pode ser tratada como uma propriedade do modelo teórico subjacente. Os parâmetros não serão identificáveis ou sê-lo-ão fracamente identificáveis se as características económicas que representam não têm, ou têm pouca, relevância empírica. Isto tanto pode ocorrer porque essas características não são importantes por si próprias, ou porque são redundantes dadas as características representadas no modelo. Estas questões são particularmente relevantes para os modelos DSGE, que são por vezes criticados por serem demasiado detalhados e, possivelmente, sobreparameterizados (Chari, Kehoe e McGrattan, 2009).

Tratar a identificação de parâmetros como uma propriedade do modelo significa que nós podemos estudá-lo sem uma referência a um particular conjunto de dados. Tal abordagem *a priori* para a identificação nem sempre é possível em econometria já que normalmente a relação entre o modelo económico e os dados observados é conhecida apenas parcialmente. Por exemplo, o grau de correlação entre os instrumentos e as variáveis endógenas do modelo linear de variáveis instrumentais simples depende de parâmetros que, na ausência de um modelo económico totalmente articulado, não têm interpretação estrutural. Em contrapartida, quando estamos num cenário de equilíbrio geral, como no caso dos modelos DSGE, todos os parâmetros de forma reduzida são funções dos parâmetros estruturais. Neste cenário, podemos estudar de que forma as propriedades dos instrumentos são determinadas ou condicionadas pelas do modelo subjacente.

No que segue utilizam-se três exemplos, puramente estatísticos e dois modelos DSGE simples,

* O autor agradece os comentários de João Sousa. As opiniões expressas no artigo são da responsabilidade do autor, não coincidindo necessariamente com as do Banco de Portugal ou do Eurosistema. Eventuais erros e omissões são da exclusiva responsabilidade do autor.

** Banco de Portugal, Departamento de Estudos Económicos.

para ilustrar a análise *a priori* de identificação e o tipo de perguntas que podem ser respondidas com este método. A apresentação baseia-se em diversos estudos: em Iskrev (2010a) é explicado como determinar se os parâmetros de um modelo DSGE são identificados; Iskrev (2010a) mostra como avaliar a intensidade da identificação dos parâmetros identificados; Iskrev (2010b) discute o papel das variáveis observáveis na estimação de modelos DSGE.

2. UM EXEMPLO SIMPLES

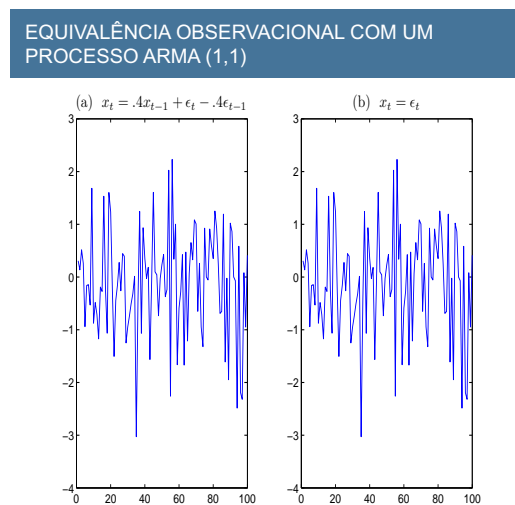
Nesta secção, utiliza-se um modelo simples para discutir o problema da identificação e explicar a principal ideia por detrás da abordagem da análise de identificação *a priori*.

Considere o seguinte processo auto regressivo de média móvel (ARMA (1,1)):

$$x_t = \phi_1 x_{t-1} + \varepsilon_t - \phi_2 \varepsilon_{t-1}, \quad |\phi_1| < 1, |\phi_2| < 1, \quad \varepsilon_t \sim \mathbb{N}(0, \sigma^2) \quad (2.1)$$

O painel (a) do Gráfico 1 mostra 100 observações geradas por (2.1) com $\phi_1 = \phi_2 = 0.4$, $\sigma = 1$. O painel (b) mostra as realizações do termo ε_t , $t = 1, \dots, T$ usado para gerar as observações para x_t . As duas séries x_t e ε_t são idênticas.

Gráfico 1



Fonte: Cálculos do autor.

Este exemplo ilustra o que é chamado em econometria de *equivalência observacional*: há dois valores do vetor de parâmetros $\theta = [\phi_1, \phi_2, \sigma]'$, $\theta_1 = [.4, .4, 1]'$ e $\theta_2 = [0, 0, 1]'$, que podem produzir as mesmas observações para x_t . De facto, no modelo ARMA(1,1) há um número infinito de combinações de tais valores. Desde que se mantenha σ fixo, e ϕ_1 for igual a ϕ_2 , as realizações de x_t são indistinguíveis das de ε_t .

A razão para essa equivalência observacional é fácil de compreender se considerarmos a função de auto covariância (ACF), que para um processo ARMA (1,1) é dada por:

$$\begin{aligned}\gamma_0 &= (x_t^2) = \frac{(1 + \phi_2^2 - 2\phi_1\phi_2)\sigma^2}{1 - \phi_1^2} \\ \gamma_1 &= (x_t x_{t-1}) = \frac{(\phi_1 - \phi_2)(1 - \phi_1\phi_2)\sigma^2}{1 - \phi_1^2} \\ \gamma_h &= (x_t x_{t-h}) = \phi_1 \gamma_{h-1}, \quad h \geq 2\end{aligned}\tag{2.2}$$


A partir da definição é claro que $\phi_1 = \phi_2$ é equivalente a $\gamma_0 = \sigma^2$, $\gamma_k = 0$, $k \geq 1$. Portanto, quando os valores do coeficiente do termo auto regressivo são iguais aos do termo da média móvel, a função auto correlação do processo ARMA (1,1) x_t é idêntica à do processo de ruído branco ε_t . Isto implica que não podemos distinguir os dados gerados a partir de um modelo ARMA (1,1) de processo com um valor arbitrário para $\phi_1 = \phi_2$ a partir dos dados gerados a partir de um ARMA(1,1) $\phi_1 = \phi_2 = 0$.

Agora, considere o Gráfico 2, que mostra duas séries de 100 observações geradas por (2.1) com $\theta_1 = [0, 0, 1]$ (linha sólida) e $\theta_2 = [7, .8, 1]$ (linha tracejada), utilizando as mesmas realizações de ε_t . Claramente, as duas séries são muito semelhantes, embora não idênticas. Neste caso temos um exemplo de quase equivalência observacional: os dados gerados a partir do modelo ARMA (1,1) com $\phi_1 \approx \phi_2$ são difíceis de distinguir dos dados gerados pelo modelo com valores arbitrários de $\phi_1 = \phi_2$ e o mesmo valor de σ .

Como podemos detetar a falta de identificação (equivalência observacional) de uma situação de fraca identificação (quase equivalência observacional)? Um poderoso resultado, devido a Rothenberg

Gráfico 2

QUASE EQUIVALÊNCIA OBSERVACIONAL COM UM PROCESSO ARMA (1,1)



Fonte: Cálculos do autor.

(1971), prevê uma condição necessária geral e suficiente para a identificação, a saber, que a matriz informação não é singular. Como Rothenberg (1971) salienta, a matriz informação “é uma medida da quantidade de informação sobre os parâmetros desconhecidos disponível na amostra”. Um parâmetro não é identificado quando não há nenhuma informação sobre o mesmo na amostra, ou se a informação existente é insuficiente para distinguir esse parâmetro de outros parâmetros do modelo. Ambos os casos resultam numa matriz informação singular.

No caso do modelo ARMA (1,1), a matriz informação é dada por:

$$\mathcal{I}(\phi_1, \phi_2) = \begin{bmatrix} \frac{1}{1-\phi_1^2} & \frac{-1}{1-\phi_1\phi_2} \\ \frac{-1}{1-\phi_1\phi_2} & \frac{1}{1-\phi_2^2} \end{bmatrix} \quad (2.3)$$

De (2.4) podemos calcular o determinante de $\mathcal{I}(\phi_1, \phi_1)$

$$\det(\mathcal{I}(\phi_1, \phi_2)) = \frac{(\phi_1 - \phi_2)^2}{(1 - \phi_1\phi_2)^2(1 - \phi_1^2)(1 - \phi_2^2)} \quad (2.4)$$

Uma vez que a não singularidade é equivalente ao determinante da matriz ser diferente de zero, a partir de (2.4) é imediato que ter $\phi_1 \neq \phi_2$ é necessário e suficiente para a identificação do modelo ARMA (1,1).

A matriz informação também é útil para detetar problemas de identificação fraca. Um parâmetro é identificado, mas quando a informação na amostra é muito limitada, pode ser difícil distinguir esse parâmetro de outros parâmetros. Neste caso, a matriz de informação poderá ser de característica plena, mas estar muito perto de ser singular. O grau de identificação pode ser medido utilizando o resultado que a matriz de covariância assintótica de um estimador eficiente é igual ao inverso da matriz de informação dividido pela dimensão da amostra. Assim, as variâncias assintóticas dos estimadores dos parâmetros ARMA ϕ_1 e ϕ_2 são:

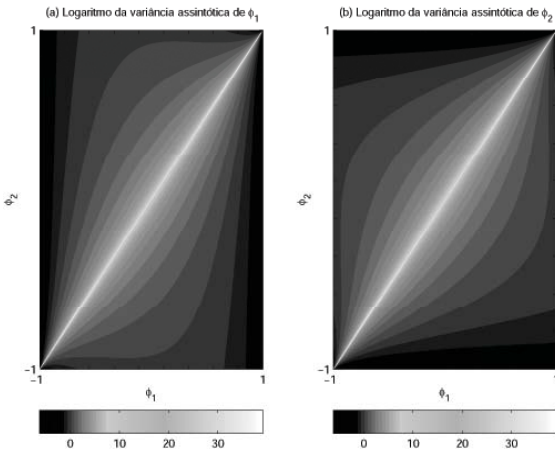
$$\text{var}(\hat{\phi}_1) = \frac{(1 - \phi_1\phi_2)^2(1 - \phi_1^2)}{T(\phi_1 - \phi_2)^2}, \quad \text{var}(\hat{\phi}_2) = \frac{(1 - \phi_1\phi_2)^2(1 - \phi_2^2)}{T(\phi_1 - \phi_2)^2} \quad (2.5)$$

As fórmulas em (2.5) revelam que as variâncias dos estimadores são grandes quando assintoticamente $\phi_1 \approx \phi_2$. Isto sugere que as estimativas dos parâmetros auto regressivos e das médias móveis serão muito imprecisos quando os seus verdadeiros valores são semelhantes. Portanto, ϕ_1 e ϕ_2 são fracamente identificados.

Note-se que ambos os desvios em (2.5) dependem dos valores de ϕ_1 e ϕ_2 . Assim, para uma determinada dimensão da amostra T , a intensidade da identificação de cada parâmetro depende dos verdadeiros valores de ambos os parâmetros. Isto pode ser visto claramente no Gráfico 3, que mostra como as variâncias assintóticas variam em diferentes regiões no espaço de parâmetros.

Gráfico 3

VARIÂNCIAS ASSINTÓTICAS DOS PARÂMETROS DE UM PROCESSO ARMA (1,1)



Fonte: Cálculos do autor.

Para ganhar alguma intuição sobre a relação entre os valores dos parâmetros e a intensidade da identificação, considere a seguinte decomposição da matriz de informação (2.4)

$$\mathcal{I}(\phi_1, \phi_2) = \begin{bmatrix} \frac{1}{\sqrt{1-\phi_1^2}} & 0 \\ 0 & \frac{1}{\sqrt{1-\phi_2^2}} \end{bmatrix} \begin{bmatrix} 1 & \frac{\sqrt{(1-\phi_1^2)(1-\phi_2^2)}}{\phi_1\phi_2-1} \\ \frac{\sqrt{(1-\phi_1^2)(1-\phi_2^2)}}{\phi_1\phi_2-1} & 1 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{1-\phi_1^2}} & 0 \\ 0 & \frac{1}{\sqrt{1-\phi_2^2}} \end{bmatrix} \quad (2.6)$$

Note-se que o primeiro e o último termo do lado direito são os mesmos da matriz diagonal com elementos iguais à raiz quadrada dos elementos da diagonal de $\mathcal{I}(\phi_1, \phi_2)$. Esta matriz dá-nos uma indicação relativamente à informação sobre cada parâmetro contida na amostra, assumindo que o outro parâmetro é conhecido. Por exemplo, $(1-\phi_1^2)/T$ é a variância assintótica de um estimador eficiente de ϕ_1 se ϕ_2 for conhecido. Portanto, $|\phi_1|$ estará tanto mais perto de 1, quanto mais informação houver acerca de ϕ_1 , para um dado valor de ϕ_2 . Da mesma forma, $|\phi_2|$ estará tanto mais próximo de 1 quanto mais informação houver sobre ϕ_2 , para um dado valor de ϕ_1 .

Em seguida, considere-se a matriz do meio. É uma matriz de correlação que nos diz quão similar é o efeito sobre a distribuição de x_t de uma pequena mudança num parâmetro, digamos ϕ_1 , a uma pequena mudança noutro parâmetro, por exemplo, ϕ_2 . Observe-se que $\mathcal{I}(\phi_1, \phi_2)$ é singular somente quando a matriz de correlação em (2.6) é singular, o que ocorre se e somente se o elemento fora da diagonal, $\frac{\sqrt{(1-\phi_1^2)(1-\phi_2^2)}}{\phi_1\phi_2-1}$ for igual a -1. Neste caso, uma pequena mudança, digamos um aumento de ϕ_1 , tem exatamente o mesmo efeito que uma pequena diminuição noutro parâmetro. Quando a correlação é próxima mas diferente de 1 em valor absoluto, o efeito de alterar um parâmetro é quase o mesmo à de mudar o outro. Portanto, o termo do meio em (2.6) representa a perda de informação sobre o parâmetro devido à incerteza quanto ao verdadeiro valor de outros parâmetros.

A abordagem da matriz de informação para a identificação só é possível quando a distribuição dos

dados é conhecida. E se não se puder ou não se quiser assumir que ε_t em (2.1) é normalmente distribuído? Uma abordagem razoável neste caso é basear a análise de identificação na função auto correlação de x_t . Como já vimos, é muito simples determinar a não-identificabilidade dos parâmetros auto regressivos e de média móvel $\phi_1 = \phi_2$ usando a função auto correlação teórica do processo ARMA(1,1) Mais formalmente, podemos proceder da seguinte maneira: seja $\gamma = [\gamma_0, \gamma_1, \dots, \gamma_{k-1}]$ o vetor das primeiras k -auto covariâncias de x_t . Então θ é identificado em θ_0 se a matriz de dimensão $k \times 3$ $\partial\gamma / \partial \theta$ tem característica igual a 3, quando avaliado em θ_0 . A intuição por trás dessa condição é muito simples: a matriz tem característica plena (igual à dimensão de θ) se e somente se os vetores $\partial\gamma / \partial\phi_1, \partial\gamma / \partial\phi_2, \partial\gamma / \partial\sigma$ forem linearmente independentes. Para isso não deve ser possível reproduzir o efeito sobre os momentos da alteração de um parâmetro alterando os outros dois parâmetros. Isto é, cada parâmetro tem um papel distinto na determinação das propriedades do modelo, que é o que exige a identificação.

A identificação fraca, por outro lado, significa que o efeito de alterar um parâmetro sobre os momentos de x_t pode ser aproximado muito de perto pela alteração do valor de outros parâmetros. Isso resulta em derivadas que são quase linearmente dependentes. Por exemplo, ter colinearidade entre $\partial\gamma / \partial\phi_1$ e $\partial\gamma / \partial\phi_2$ de cerca de um (em valor absoluto) significa que o efeito de uma alteração do valor de ϕ_1 em γ é muito semelhante ao de mudar ϕ_2 .

O Quadro 1 ilustra a abordagem de identificação baseada em momentos no modelo ARMA (1,1). As colunas 2-4 mostram os valores das derivadas das primeiras 10 auto covariâncias quando os verdadeiros valores dos parâmetros são $\phi_1 = \phi_2 = 0, \sigma = 1$. Como podemos ver, as derivadas em relação a ϕ_1 e ϕ_2 estão perfeitamente correlacionadas negativamente. Assim, a característica de $\partial\gamma / \partial\theta$ é só 2 e ϕ_1 e ϕ_2 não são identificados. As colunas 5-7 também apresentam as derivadas de γ avaliadas em $\phi_1 = .7, \phi_2 = .8, \sigma = 1$. O grau de colinearidade entre $\partial\gamma / \partial\phi_1$ e $\partial\gamma / \partial\phi_2$ é $-.98$, que é elevado, mas inferior a -1. Assim, ϕ_1 e ϕ_2 ainda são identificados embora apenas fracamente.

Quadro1

DERIVADA DA ACF DE UM PROCESSO ARMA						
$\gamma(i)$	$\phi_1 = 0, \phi_2 = 0, \sigma = 1$			$\phi_1 = .7, \phi_2 = .8, \sigma = 1$		
	$\partial\gamma / \partial\phi_1$	$\partial\gamma / \partial\phi_2$	$\partial\gamma / \partial\sigma$	$\partial\gamma / \partial\phi_1$	$\partial\gamma / \partial\phi_2$	$\partial\gamma / \partial\sigma$
0	0.00	-0.00	4.00	-1.35	1.57	4.08
1	4.00	-4.00	0.00	3.13	-2.90	-0.35
2	1.60	-1.60	0.00	1.85	-2.03	-0.24
3	0.64	-0.64	0.00	1.05	-1.42	-0.17
4	0.26	-0.26	0.00	0.57	-1.00	-0.12
5	0.10	-0.10	0.00	0.28	-0.70	-0.08
6	0.04	-0.04	0.00	0.11	-0.49	-0.06
7	0.02	-0.02	0.00	0.02	-0.34	-0.04
8	0.01	-0.01	0.00	-0.03	-0.24	-0.03
9	0.00	-0.00	0.00	-0.05	-0.17	-0.02
10	0.00	-0.00	0.00	-0.05	-0.12	-0.01

Fonte: Cálculos do autor.

3. MODELOS DSGE

Nesta secção discute-se a identificação de parâmetros em modelos DSGE. Começa-se com uma breve descrição geral do método e, em seguida, analisam-se dois modelos DSGE.

3.1. Generalidades

Um modelo DSGE é resumido por um sistema de equações não-lineares. Atualmente, a maioria dos estudos envolvendo a simulação ou qualquer estimativa de modelos DSGE utiliza aproximações (log) lineares dos modelos originais. Ou seja, o modelo é expresso pela primeira vez em termos de variáveis estacionárias, e, em seguida, linearizado em torno dos valores de estado estacionário das variáveis. Uma vez linearizados, a maioria dos modelos DSGE podem ser escritos da seguinte forma:

$$\Gamma_0(\theta)z_t = \Gamma_1(\theta)E_t z_{t+1} + \Gamma_2(\theta)z_{t-1} + \Gamma_3(\theta)u_t \quad (3.1)$$

onde z_t é um vetor m -dimensional das variáveis estado endógenas e exógenas, os choques estruturais u_t são vetores aleatórios n -dimensionais independentes e identicamente distribuídos com $E u_t = 0$, $E u_t u_t' = I_n$. Os elementos de Γ_0 , Γ_1 , Γ_2 e Γ_3 são funções de um vetor k -dimensional dos parâmetros estruturais θ , onde θ é um ponto em $\Theta \subset \mathbb{R}^k$. O espaço dos parâmetros Θ é definido como o conjunto de todos os valores teoricamente admissíveis de θ .

Existem vários algoritmos para a resolução de modelos lineares de expectativas racionais (ver, por exemplo Blanchard e Kahn, (1980), AIM, (1985), Klein, (2000), Christiano, (2002), e Sims, (2002)). Dependendo do valor de θ , podem existir zero, uma ou várias soluções estáveis. Assumindo que existe uma solução única:

$$z_t = A(\theta)z_{t-1} + B(\theta)u_t \quad (3.2)$$

onde a matriz $(A m \times m)$ e a matriz $(B m \times n)$ são únicas para cada valor de θ .

O modelo em (3.2) não pode ser estimado diretamente dado que algumas das variáveis em z_t não são observadas. Em vez disso, a solução do modelo é expressa sob a forma de espaço de estados, com uma equação de transição dada por (3.2), e uma equação de medição dada por:

$$x_t = s(\theta) + C(\theta)z_t \quad (3.3)$$

onde x_t é um vetor l -dimensional das variáveis de estado observado, s é um vetor l -dimensional, e C é uma matriz de dimensão $l \times m$.

A função log-verosimilhança dos dados $X = [x_1, \dots, x_T]$ pode ser calculada usando o filtro de Kalman se os choques estruturais u_t forem (supostamente) um conjunto normalmente distribuído. Neste caso, a matriz de informação esperada pode ser derivada analiticamente, como discutido em Iskrev, (2008).

3.2. Identificação do modelo de ciclos económicos reais

O primeiro modelo que eu considero é uma versão do modelo de crescimento estocástico com um setor de Hansen, (1985) com choques tecnológicos específicos sobre o investimento. Abaixo descrevem-se as principais características do modelo.

3.2.1 O modelo

As preferências representativas das famílias são caracterizadas pela função de utilidade:

$$E_0 \sum_{t=0}^{\infty} \beta^t (\ln(c_t) - \phi n_t) \quad (3.4)$$

onde c_t é o consumo no período t e n_t é o trabalho total fornecido pela família.

A produção utiliza capital k_t e trabalho com a função de produção que se segue:

$$y_t = \exp(z_t) k_t^{1-\alpha} n_t^\alpha \quad (3.5)$$

onde Z_t é a produtividade total dos fatores e segue um processo AR(1):

$$z_t = \rho_z z_{t-1} + \varepsilon_t^z, \quad \varepsilon_t^z \sim (0, \sigma_z^2) \quad (3.6)$$

A evolução do stock de capital é dada por:

$$k_{t+1} = (1 - \delta)k_t + \exp(u_t)i_t \quad (3.7)$$

onde u_t é a tecnologia específica do investimento que segue um processo AR(1):

$$u_t = \rho_u u_{t-1} + \varepsilon_t^u, \quad \varepsilon_t^u \sim \mathbb{N}(0, \sigma_u^2) \quad (3.8)$$

A restrição de recursos da economia é:

$$c_t + i_t = y_t \quad (3.9)$$

3.2.2 Análise de identificação

O modelo é log-linearizado em torno do estado estacionário determinístico das variáveis, e o sistema é expresso em (3.2). Há quatro variáveis potencialmente observáveis: produção, consumo, horas trabalhadas e investimento. Uma vez que existem apenas dois choques estruturais, podemos usar no máximo duas variáveis para estimar o modelo por máxima verosimilhança; essas podem ser quaisquer duas variáveis, ou algumas combinações lineares das mesmas. O modelo possui 8 parâmetros estruturais, que são reunidos no vetor $\theta = [\alpha, \beta, \delta, \phi, \rho_z, \rho_u, \sigma_z, \sigma_u]$.

Vamos primeiro considerar o caso de uma única variável observada. Este é um exercício útil, pois diz-nos qual a variável que é mais informativa para identificar os parâmetros (identificáveis). Neste caso, na equação de medição (3.3) x_t e s são escalares, e C é um vetor linha com 1 na posição das variáveis observadas e zeros nas restantes posições. A identificabilidade de θ pode ser estabelecida usando a matriz de informação ou a abordagem baseada em momentos. Ambos os métodos implicam que dois dos oito parâmetros não são identificados, nomeadamente β e δ , que, quando há apenas uma variável observável, e independentemente qual delas é, não podem ser identificados separadamente. Isso é fácil de ver notando que as derivadas dos momentos em relação a β e δ são colineares. No entanto, se se fixarem valores para β ou δ , os restantes sete parâmetros passam a ser identificados. O Quadro 2 mostra os desvios-padrão assintóticos relativos, definidos como $\frac{std(\hat{\theta}_i)}{|\theta_i|}$ assumindo que β ou δ são conhecidos. Note-se que existem diferenças substanciais na precisão com que os parâmetros podem ser estimados, dependendo de qual variável é utilizada e também de qual dos parâmetros (β ou δ) é conhecido. Por exemplo, a produção (y) é mais informativa para identificar α se β for conhecido e δ estimado, mas as horas trabalhadas (n) são mais informativas quando β é estimado e δ conhecido. A razão pela qual os desvios padrões relativos são reportados é que eles fornecem uma medida da intensidade da identificação, que é independente do valor do parâmetro. Isto permite-nos determinar quais os parâmetros que são relativamente melhor e quais são relativamente pior identificados.

Os resultados no Quadro 2 sugerem que, embora seja possível estimar a maioria dos parâmetros com apenas uma variável observável, as estimativas tendem a ser muito imprecisas. Com duas variáveis observadas há muito mais informação sobre os parâmetros e, portanto, a incerteza das estimativas, capturada pelo desvio-padrão assintótico, é muito reduzida. Isto pode ser visto no Quadro 3, que relata a relação assintótica dos desvios-padrão com cada par de observáveis. Do quadro, podemos ver que todos os parâmetros são identificados; em geral, os parâmetros melhor identificados são β , ρ_z e ρ_u , enquanto os pior identificados são ϕ , σ_z e σ_u .

Para determinar as razões de alguns parâmetros serem melhor e outros pior identificados, podemos usar a decomposição da matriz de informação análoga à da equação (2.6). Podemos expressar

Quadro 2

INTENSIDADE DA IDENTIFICAÇÃO DO MODELO RBC COM UMA VARIÁVEL OBSERVÁVEL									
Par.	Valor	c	y	i	n	c	y	i	n
α	0.670	187	35	135	62	197	97	11797	30
ϕ	0.025	981	3103	656	268	fixo	fixo	fixo	fixo
δ	0.980	fixo	fixo	fixo	fixo	26	98	1667	6.1
β	2.000	287	652	918	8.4	289	1246	58	47
ρ_z	0.950	5.6	20	37	29	5.6	20	37	29
ρ_u	0.970	8.6	17	32	20	8.6	17	32	20
σ_z	1.000	241	103	545	952	250	257	7497	1097
σ_u	1.000	306	1843	2401	1051	289	2102	927	929

Fonte: Cálculos do autor.

Nota: Cada coluna da tabela mostra os desvios padrão relativos assintóticos de θ quando há apenas uma variável observada (mostrada na primeira linha) e se assume que β ou δ é conhecido. Os resultados são obtidos utilizando o valor esperado da matriz de informação e $T = 100$.

Quadro 3

INTENSIDADE DA IDENTIFICAÇÃO NO MODELO RBC COM DUAS VARIÁVEIS OBSERVÁVEIS							
Par.	Valor	(c,y)	(c,i)	(c,n)	(y,i)	(y,n)	(i,n)
α	0.670	0.325	0.274	0.321	0.285	0.307	0.288
δ	0.025	1.027	0.454	1.125	0.454	1.119	0.453
β	0.980	0.024	0.025	0.025	0.018	0.025	0.021
ϕ	2.000	3.005	1.958	1.178	1.420	1.164	0.726
ρ_z	0.950	0.033	0.059	0.033	0.050	0.033	0.043
ρ_u	0.970	0.052	0.051	0.051	0.051	0.050	0.052
σ_z	1.000	0.299	0.381	0.295	0.264	0.283	0.346
σ_u	1.000	0.604	0.606	0.590	0.679	0.582	0.717

Fonte: Cálculos do autor.

Nota: Cada coluna da tabela mostra os desvios padrão relativos assintóticos de θ quando há apenas uma variável observada (mostrada na primeira linha). Os resultados são obtidos utilizando o valor esperado da matriz de informação e $T = 100$.

o desvio padrão relativo para um determinado parâmetro como um produto de dois termos: uma componente de sensibilidade, que é grande para os parâmetros que não desempenham um papel importante no modelo, e uma componente de colinearidade, que é grande para parâmetros cujo papel no modelo é fácil de aproximar com outros parâmetros. Esta decomposição é mostrada na Quadro 4. Podemos ver que a razão pela qual β é tão bem identificado é que a sua componente de sensibilidade é muito baixa, o que implica que β é um determinante importante das propriedades empíricas das variáveis do modelo. No outro extremo temos ϕ , que tem uma componente sensibilidade muito grande, e por isso é o parâmetro pior identificado. A forte colinearidade explica a diferente intensidade da identificação de σ_z e σ_u , que têm a mesma componente de sensibilidade. Outros parâmetros com forte colinearidade são α , δ e ρ_u . Como já foi discutido na Secção 2, a colinearidade forte significa que dois ou mais parâmetros desempenham um papel similar no modelo. É interessante saber quais são esses parâmetros. Uma maneira simples de descobrir é calcular medi-

Quadro 4

SENSIBILIDADE E COLINEARIDADE NO MODELO RBC COM DUAS VARIÁVEIS OBSERVÁVEIS												
Par.	(c,y)		(c,i)		(c,n)		(y,i)		(y,n)		(i,n)	
	sens.	col.	sens.	col.	sens.	col.	sens.	col.	sens.	col.	sens.	col.
α	0.056	5.8	0.028	9.7	0.057	5.7	0.014	19.8	0.057	5.4	0.003	93.2
δ	0.191	5.4	0.087	5.2	0.191	5.9	0.045	10.0	0.192	5.8	0.015	30.0
β	0.005	4.8	0.005	5.0	0.005	5.0	0.001	13.6	0.005	5.0	0.000	73.4
ϕ	2.374	1.3	1.799	1.1	1.127	1.0	1.195	1.2	1.100	1.1	0.647	1.1
ρ_z	0.014	2.4	0.014	4.2	0.014	2.4	0.014	3.6	0.014	2.4	0.014	3.1
ρ_u	0.008	6.5	0.008	6.5	0.008	6.4	0.008	6.5	0.008	6.4	0.008	6.5
σ_z	0.071	4.2	0.071	5.4	0.071	4.2	0.071	3.7	0.071	4.0	0.071	4.9
σ_u	0.071	8.5	0.071	8.5	0.071	8.3	0.071	9.6	0.071	8.2	0.071	10.1

Fonte: Cálculos do autor.

Nota: Cada coluna do quadro mostra as componentes de sensibilidade e de colinearidade dos desvios padrão relativos assintóticos de θ quando existem duas variáveis observadas (mostradas na primeira linha). Os resultados são obtidos utilizando o valor esperado da matriz de informação e $T = 100$.

Quadro 5

INTENSIDADE DA COLINEARIDADE ENTRE PARES DE PARÂMETROS DO MODELO RBC COM DUAS VARIÁVEIS OBSERVÁVEIS

Par.	(c,y)		(c,i)		(c,n)		(y,i)		(y,n)		(i,n)	
	pcol	par.	pcol	par.	pcol	par.	pcol	par.	pcol	par.	pcol	par.
α	0.70	σ_z	-0.95	β	0.71	σ_z	-0.98	δ	0.71	σ_z	-0.999	β
δ	-0.97	β	-0.74	α	-0.98	β	-0.98	α	-0.98	β	-0.997	α
β	-0.97	δ	-0.95	α	-0.98	δ	-0.96	α	-0.98	δ	-0.999	α
ϕ	0.12	α	0.04	α	-0.04	α	0.04	α	-0.06	α	-0.004	α
ρ_z	-0.56	β	-0.65	α	-0.56	β	-0.49	α	-0.56	β	-0.12	β
ρ_u	-0.97	σ_u	-0.97	σ_u	-0.97	σ_u	-0.97	σ_u	-0.97	σ_u	-0.97	σ_u
σ_z	0.70	α	0.72	α	0.71	α	0.45	α	0.71	α	-0.71	δ
σ_u	-0.97	ρ_u	-0.97	ρ_u	-0.97	ρ_u	-0.97	ρ_u	-0.97	ρ_u	-0.97	ρ_u

Fonte: Cálculos do autor.

Nota: O quadro mostra os parâmetros que estão mais fortemente relacionadas com cada parâmetro estrutural, bem como o valor da colinearidade entre pares de coeficientes (*pcol*). Os resultados são obtidos utilizando o valor esperado da matriz informação e $T = 100$.

das da colinearidade para pares de coeficientes, que medem a semelhança entre os efeitos de dois parâmetros. Isso é feito no Quadro 5 e podemos ver que há uma forte colinearidade negativa entre σ_u e ρ_u por um lado, e entre β e δ , por outro. Assim, ter maior volatilidade do choque específico ao investimento é semelhante a ter menor persistência do choque, e ter consumidores mais pacientes é semelhante a ter uma menor taxa de depreciação do capital. Além disso, também podemos ver que quando a produção e o investimento estão incluídos no conjunto das variáveis observadas, α é altamente colinear com β e δ . Isso significa que os efeitos desses parâmetros sobre os momentos e momentos cruzados da produção e investimento são difíceis de distinguir.

3.3. Identificação no modelo Neo-Keynesiano

Nesta secção, considero um modelo *Neo-Keynesiano* de escala reduzida estudado em An e Schorfheide, (2007). Segue-se uma breve descrição do modelo.

3.3.1 O modelo

A família representativa maximiza a seguinte função utilidade

$$E_t \left[\sum_{s=0}^{\infty} \beta^s \left(\frac{(C_{t+s} / A_{t+s} - 1)^{1-\tau}}{1-\tau} - N_{t+s} \right) \right], \quad (3.10)$$

sujeita a uma restrição orçamental:

$$P_t C_t + B_t + T_t = P_t W_t N_t + R_{t-1} B_{t-1} + P_t D_t + P_t S C_t, \quad (3.11)$$

onde C_{t+s} é o consumo, $N_{t+s}(j)$ as horas trabalhadas, P_t é o preço final do bem, W_t é o salário real, R_t representa os juros sobre os títulos do Estado B_t , D_t é o lucro residual em termos reais, T_t são os impostos *lump-sum* e $S C_t$ é o fluxo de caixa líquido da negociação de valores mobiliários

cujo valor é contingente ao estado da economia. A_t é o *stock* de hábito determinado pelo nível de tecnologia no setor de bens intermédios, e evolui de acordo com

$$\Delta \ln A_t = \ln \gamma + \ln z_t, \quad \ln z_t = \rho_z \ln z_{t-1} + \varepsilon_t^z, \quad \varepsilon_t^z \sim \mathbb{N}(0, \sigma_z^2)$$

Há um setor perfeitamente competitivo produzindo um único bem final a partir de *inputs* intermédios $Y_t(j)$ usando a tecnologia

$$Y_t = \left(\int_0^1 Y_t(j)^{1-\nu} dj \right)^{\frac{1}{1-\nu}} \quad (3.12)$$

A empresa de bens finais maximiza os lucros dados por

$$P_t Y_t - \int_0^1 P_t(i) Y_t(i) di, \quad (3.13)$$

onde $P_t(i)$ é o preço do bem intermédio $Y_t(i)$.

Os bens intermédios são produzidos num setor de concorrência monopolista. Cada variedade i é produzida por uma única empresa a utilizar a tecnologia de produção que se segue:

$$Y_t(i) = A_t N_t(i) \quad (3.14)$$

A empresa de bens intermédios j maximiza o valor presente de seus lucros futuros

$$E_t \left[\sum_{s=0}^{\infty} \beta^s Q_{t+s|t} \left(\frac{P_{t+s}(j)}{P_{t+s}} Y_{t+s}(j) - W_{t+s} N_{t+s}(j) - A C_{t+s}(j) \right) \right], \quad (3.15)$$

onde $Q_{t+s|t}$ é o valor para os consumidores no período t de uma unidade do bem final do período $t+s$; $A C_t(j) = \frac{\phi}{2} \left(\frac{P_t(j)}{P_{t-1}(j)} - \pi \right)^2 Y_t(j)$ é o custo do ajustamento dos preços e π é a taxa de estado estacionário da inflação.

O Banco Central fixa a taxa de juro nominal de acordo com a seguinte regra:

$$\frac{R_t}{r^* \pi^*} = \exp(\varepsilon_t^r) \left(\frac{R_{t-1}}{r^* \pi^*} \right)^{\rho_r} \left[\left(\frac{\pi_t}{\pi^*} \right)^{\psi_1} \left(\frac{Y_t}{Y_{t-1} \gamma} \right)^{\psi_2} \right]^{1-\rho_r}, \quad (3.16)$$

onde r^* é o estado estacionário taxa de juro real, π_t é a taxa de inflação bruta, π^* é o objetivo para a taxa de inflação (em termos brutos), e $\varepsilon_t^r \sim \mathbb{N}(0, \sigma_r^2)$ é um choque de política monetária.

O governo cobra impostos *lump-sum*, a fim de financiar o seu consumo, de modo a respeitar a seguinte restrição orçamental

$$P_t G_t + B_{t-1} R_{t-1} = T_t + B_t, \quad (3.17)$$

onde $G_t = \zeta_t Y$ é o consumo do governo em termos de bem final, e $\zeta_t = 1 - 1/g_t$ onde g_t é uma variável aleatória evoluindo de acordo com

$$\ln g_t = (1 - \rho_g) \ln g + \rho_g \ln g_{t-1} + \varepsilon_t^g, \quad \varepsilon_t^g \sim \mathbb{N}(0, \sigma_g^2)$$

3.3.2 Análise de identificação

O modelo é log-linearizado em torno do estado estacionário determinístico das variáveis, e o sistema pode ser expresso como em (3.2). Há quatro variáveis potencialmente observáveis: produção, consumo, inflação e taxa de juro nominal. Uma vez que existem apenas três choques estruturais, podemos usar, no máximo, três variáveis para estimar o modelo por máxima verosimilhança. O modelo tem 14 parâmetros fundamentais, que são coletados no vetor $\theta = [\tau, \nu, \phi, \psi_1, \psi_2, \rho_r, \rho_g, \rho_z, r^*, \pi^*, \gamma, \sigma_r, \sigma_g, \sigma_z]$.

Vamos primeiro considerar a identificação com apenas duas variáveis observadas. Dois dos 14 parâmetros, ϕ e ν , não são identificáveis com nenhum par de observáveis. Examinando as derivadas dos momentos constata-se que tal é devido à colinearidade perfeita das derivadas em relação a esses dois parâmetros. Portanto, se se fixar qualquer um dos dois parâmetros, o outro seria identificado, juntamente com os outros 12 parâmetros. Uma exceção a essa conclusão é o caso em que apenas a produção e o consumo são observados. Então nós temos que fixar mais três parâmetros, além de ν ou ϕ . Por exemplo, se fixarmos ν , ψ_2 , π^* e σ_r , podemos identificar os restantes 10 parâmetros. O motivo para o par (produção, consumo) ser menos informativo é que o comportamento das duas variáveis no modelo é muito semelhante. Portanto, o consumo adiciona pouca informação à que já está contida no produto. Isto pode ser visto no Quadro 6, que mostra os desvios-padrão relativos assintóticos para cada par de observáveis, supondo que alguns dos elementos de θ são conhecidos. A incerteza das estimativas da maioria dos parâmetros é muito maior, comparado ao de outros pares observáveis, embora se assuma que se conhecem mais parâmetros. Note-se que, como no modelo RBC, há uma diferença substancial no conteúdo de informação de diferentes variáveis. Adicionalmente, a escolha do melhor par de variáveis para estimar os parâmetros depende do parâmetro de interesse. Por exemplo, o parâmetro da resposta da política monetária à inflação ψ_1 é mais facilmente identificado com (π, r) , enquanto a reação da política monetária ao crescimento da produção ψ_2 é melhor identificada com o par (y, r) .

Em seguida, considere-se o uso de três das quatro variáveis observáveis para estimar θ . O Quadro 7 mostra os desvios-padrão assintóticos para cada trio de parâmetros assumindo que ν ou ϕ é conhecido. Como se pode constatar no Quadro 7, fixar um dos dois parâmetros não tem nenhum efeito sobre o desvio-padrão dos outros parâmetros. Pior identificados com todas as combinações de variáveis são os coeficientes de resposta da regra de Taylor (ψ_1 e ψ_2), a rigidez dos preços e o inverso da elasticidade da procura (ϕ e ν), e a taxa de juro no estado estacionário (r^*); melhor identificados são a taxa de juro do parâmetro de alisamento (ρ_r) e o parâmetro auto regressivo do choque ao consumo público ρ_g .

O Quadro 8 mostra a decomposição dos desvios-padrão relativos nas componentes de sensibilidade e de colinearidade. Note-se que a maioria dos parâmetros pior identificados são também aqueles que têm componentes de colinearidade maiores. Assim, esses parâmetros estão mal identificados

Quadro 6

IDENTIFICAÇÃO DE PARÂMETROS NO MODELO NKM COM DUAS VARIÁVEIS OBSERVÁVEIS													
Par.	Valor	(y, π)	(y, r)	(y, c)	(π , r)	(π , c)	(r, c)	(y, π)	(y, r)	(y, c)	(π , r)	(π , c)	(r, c)
τ	2.00	3.9	3.3	554	689	2.3	12	3.9	3.3	554	689	2.3	12
ν	0.10	fixo	fixo	fixo	fixo	fixo	fixo	7.5	786	614	32	2.7	3160
ϕ	7.50	8.3	873	682	36	3.0	3511	fixo	fixo	fixo	fixo	fixo	fixo
ψ_1	1.50	20	11	2719	8.9	206	90	20	11	2719	8.9	206	90
ψ_2	1.00	18	14	fixo	230	193	72.7	18.4	14.5	fixo	230	193	72
ρ_r	0.96	0.7	0.5	118	21	7.5	4.5	0.7	0.5	118	21	7.5	4.5
ρ_y	0.95	0.95	0.7	0.1	fixo	fixo	21	0.2	0.7	0.1	fixo	21.7	0.2
ρ_z	0.65	0.8	0.9	111	34	0.3	0.3	0.8	0.9	111	34	0.3	0.3
r^*	0.40	3927	4432	293802	13845	562	17825	3927	4432	293802	13845	562	17825
π^*	4.00	0.3	443	fixo	0.3	0.3	1782	0.3	443	fixo	0.3	0.3	1782
γ	0.50	0.3	0.3	0.3	2769	0.3	0.3	0.3	0.3	0.3	2769	0.3	0.3
σ_r	0.20	26	1.9	fixo	493	18	11	26	1.9	fixo	493	18	11
σ_y	0.80	2.7	2.0	0.1	596	276	80	2.7	2.0	0.1	596	276	80
σ_z	0.45	1.5	1.7	207	139	0.5	0.5	1.5	1.7	207	139	0.5	0.5

Fonte: Cálculos do autor.

Nota: Cada coluna do quadro mostra os desvios-padrão relativos assintóticos de θ quando existem duas variáveis observadas (mostradas na primeira linha) e se assume que alguns parâmetros estruturais são conhecidos. Os resultados são obtidos utilizando o valor esperado da matriz de informação e $T = 100$.

porque os seus efeitos sobre as propriedades empíricas dos observáveis são fáceis de reproduzir com outros parâmetros. Uma exceção é r^* , que é mal identificado porque tem uma componente de sensibilidade muito elevada. Este valor implica que r^* é de pouca relevância empírica. Note-se que r^* e π^* têm componentes de colinearidade elevadas quando π não está entre os observáveis. Por exemplo, o valor de π^* traduz-se num coeficiente de colinearidade múltipla .999999875¹. Isto significa que π^* é quase impossível de distinguir também a partir dos parâmetros do modelo, exceto se se controlar para o seu efeito sobre a inflação. Calculando os coeficientes de colinearidade entre pares de parâmetros, apresentados na Quadro 9, conclui-se que quando a inflação não está entre os observáveis, a colinearidade entre π^* e r^* é de .966. Também vemos que a resposta da política monetária à inflação ψ_1 é altamente colinear com o parâmetro de rigidez de preços ϕ ou do parâmetro de alisamento ρ_r , da taxa de juro, enquanto a reação ao produto de ψ_2 é altamente colinear com ψ_1 ou r^* .

(1) O coeficiente de colinearidade várias medidas do grau de colinearidade entre um determinado parâmetro e todos os parâmetros de outro modelo.

Quadro 7

IDENTIFICAÇÃO DE PARÂMETROS NO MODELO NEO-KEYNESIANO COM TRÊS VARIÁVEIS OBSERVÁVEIS									
Par.	Valor	(y, π, r)	(y, π, c)	(y, r, c)	(π, r, c)	(y, π, r)	(y, π, c)	(y, r, c)	(π, r, c)
τ	2.00	0.36	0.56	0.26	0.32	0.36	0.56	0.26	0.32
ν	0.10	fixo	fixo	fixo	fixo	0.71	1.36	188.38	0.72
ϕ	7.50	0.79	1.52	209.31	0.80	fixo	fixo	fixo	fixo
ψ_1	1.50	1.24	1.37	1.06	3.58	1.24	1.37	1.06	3.58
ψ_2	1.00	1.41	1.36	1.18	3.28	1.41	1.36	1.18	3.28
ρ_r	0.96	0.03	0.10	0.03	0.14	0.03	0.10	0.03	0.14
ρ_g	0.95	0.03	0.04	0.04	0.03	0.03	0.04	0.04	0.03
ρ_z	0.65	0.27	0.29	0.27	0.21	0.27	0.29	0.27	0.21
r^*	0.40	3.40	323.22	1062.13	3.39	3.40	323.22	1062.13	3.39
π^*	4.00	0.31	0.31	106.21	0.31	0.31	0.31	106.21	0.31
γ	0.50	0.25	0.25	0.25	0.25	0.25	0.25	0.25	0.25
σ_r	0.20	0.39	2.32	0.28	0.35	0.39	2.32	0.28	0.35
σ_g	0.80	0.15	0.07	0.07	2.22	0.15	0.07	0.07	2.22
σ_z	0.45	0.30	0.35	0.33	0.17	0.30	0.35	0.33	0.17

Fonte: Cálculos do autor.

Nota: Cada coluna do quadro mostra os desvios-padrão assintóticos relativos de θ quando existem três variáveis observadas (mostradas na primeira linha) e se assume que ν ou ϕ são conhecidos. Os resultados são obtidos utilizando o valor esperado da matriz de informação e $T = 100$.

Quadro 8

SENSIBILIDADE E COLINEARIDADE NO MODELO NEO-KEYNESIANO COM TRÊS VARIÁVEIS OBSERVÁVEIS									
Par.	(y, π, r)		(y, π, c)		(y, r, c)		(π, r, c)		
	sens.	col.	sens.	col.	sens.	col.	sens.	col.	
τ	0.045	8.1	0.043	13.1	0.027	9.7	0.030	10.7	
ϕ	0.022	36.8	0.067	22.6	0.402	520.5	0.038	21.3	
ψ_1	0.011	116.4	0.073	18.9	0.029	36.5	0.016	220.6	
ψ_2	0.021	66.7	0.295	4.6	0.058	20.4	0.035	93.6	
ρ_r	0.001	44.5	0.003	34.3	0.002	15.7	0.001	152.7	
ρ_g	0.010	2.9	0.041	1.0	0.026	1.5	0.013	2.4	
ρ_z	0.109	2.4	0.100	2.9	0.078	3.5	0.088	2.4	
r^*	0.431	7.9	21.597	15.0	0.550	1932.4	0.432	7.9	
π^*	0.010	29.7	0.033	9.3	0.053	2003.3	0.017	18.2	
γ	0.082	3.1	0.247	1.0	0.107	2.4	0.082	3.1	
σ_r	0.071	5.5	0.070	33.0	0.071	4.0	0.070	5.0	
σ_g	0.071	2.1	0.071	1.0	0.071	1.0	0.071	31.4	
σ_z	0.071	4.3	0.071	4.9	0.071	4.6	0.071	2.4	

Fonte: Cálculos do autor.

Nota: Cada coluna do quadro mostra as componentes de sensibilidade de colinearidade dos desvios-padrão assintóticos de θ quando existem três variáveis observadas (mostradas na primeira linha). Os resultados são obtidos assumindo que $\nu = .10$ é conhecido, e usando o valor esperado da matriz de informação, com $T = 100$.

Quadro 9

INTENSIDADE DA COLINEARIDADE ENTRE PARES DE PARÂMETROS NO MODELO *NEO-KEYNESIANO* COM TRÊS VARIÁVEIS OBSERVÁVEIS

Par.	(y, π, r)		(y, π, c)		(y, r, c)		(π, r, c)	
	<i>pcol.</i>	par.	<i>pcol.</i>	par.	<i>pcol.</i>	par.	<i>pcol.</i>	par.
\mathcal{T}	-0.76	ρ_r	-0.90	ϕ	-0.95	ρ_r	-0.68	ρ_r
ϕ	0.96	π^*	0.99	π^*	0.76	σ_r	0.90	π^*
ψ_1	0.92	ϕ	-0.97	ρ_r	-0.91	ρ_r	-0.89	ρ_r
ψ_2	-0.91	ψ_1	-0.87	r^*	-0.89	ψ_1	-0.89	ψ_1
ρ_r	-0.96	ϕ	0.99	σ_r	-0.95	\mathcal{T}	-0.89	ψ_1
ρ_g	-0.70	σ_g	-0.04	σ_g	-0.21	ψ_2	-0.90	σ_g
ρ_z	-0.29	ψ_2	0.87	σ_z	0.95	σ_z	0.80	σ_z
r^*	0.94	γ	0.98	ϕ	0.97	π^*	0.94	γ
π^*	0.96	ϕ	0.99	ϕ	0.97	r^*	0.90	ϕ
γ	0.94	r^*	0.03	π^*	0.91	r^*	0.94	r^*
σ_r	0.11	ρ_r	0.99	ρ_r	0.76	ϕ	0.35	ρ_r
σ_g	-0.70	ρ_g	-0.04	ρ_g	-0.01	ρ_g	-0.90	ρ_g
σ_z	0.42	ψ_2	0.87	ρ_z	0.95	ρ_z	0.80	ρ_z

Fonte: Cálculos do autor.

Nota: O quadro mostra os parâmetros que estão mais fortemente relacionados com cada parâmetro estrutural, bem como o valor da colinearidade entre pares de coeficientes (*pcol*). Os resultados são obtidos assumindo que $\nu = .10$ é conhecido, e utilizando o valor esperado da matriz de informação e $T = 100$.

4. OBSERVAÇÕES FINAIS

Nos últimos anos os modelos DSGE têm-se tornado um instrumento de análise de política cada vez mais importante. Isto levou a um considerável esforço de investigação com vista à melhoria dos modelos em termos de complexidade e realismo. Como o número de características incluídas nos modelos aumenta, torna-se difícil entender o contributo de cada uma das características em separado para o desempenho do modelo vis-à-vis a realidade que é suposto explicar. Neste artigo, tentei mostrar que o estudo da identificação de parâmetros pode fornecer dados úteis sobre os parâmetros do modelo e as características estruturais que representam. A intensidade com que um parâmetro é identificado reflete a sua importância para as implicações empíricas do modelo. A identificação é fraca quando algumas características do modelo têm pouca relevância empírica. Isto pode ocorrer porque elas não são importantes por si próprias, ou porque são redundantes, dadas as características representadas no modelo. Como os modelos DSGE fornecem uma completa caracterização da dinâmica das variáveis do modelo, a identificação dos parâmetros pode ser tratada como uma propriedade do modelo subjacente e estudado sem uma referência a um particular conjunto de dados. Esta abordagem para identificação de parâmetros foi ilustrada utilizando dois modelos canónicos macroeconómicos: um modelo de ciclos económicos reais e um modelo *neo-keynesiano*. Uma limitação desta análise é que apenas foi considerado um valor único para cada parâmetro. Para obter um quadro completo da identificação, como uma propriedade do modelo, é preciso estudá-lo em diferentes valores dos parâmetros teoricamente plausíveis. Para uma discussão mais detalhada

deste e de outros aspetos importantes da análise *a priori* de identificação, o leitor pode consultar os documentos citados na introdução.

REFERÊNCIAS

- An, S., e F. Schorfheide (2007): “Bayesian Analysis of DSGE Models”, *Econometric Reviews*, 26(2-4), 113--172.
- Anderson, G., e G. Moore (1985): “A linear algebraic procedure for solving linear perfect foresight models”, *Economics Letters*, 17(3), 247--252, <http://ideas.repec.org/a/eee/ecolet/v17y1985i3p247-252.html>.
- Blanchard, O. J., e C. M. Kahn (1980): “The Solution of Linear Difference Models under Rational Expectations”, *Econometrica*, 48(5), 1305--11, <http://ideas.repec.org/a/ecm/emetrp/v48y1980i5p1305-11.html>.
- Chari, V. V., P. J. Kehoe, e E. R. McGrattan (2009): “New Keynesian Models: Not Yet Useful for Policy Analysis”, *American Economic Journal: Macroeconomics*, 1(1), 242--66.
- Christiano, L. J. (2002): “Solving dynamic equilibrium models by a method of undetermined coefficients”, *Computational Economics*, 20(1-2).
- Hansen, G. D. (1985): “Indivisible labor and the business cycle”, *Journal of Monetary Economics*, 16(3), 309--327, <http://ideas.repec.org/a/eee/moneco/v16y1985i3p309-327.html>.
- Iskrev, N. (2008): “Evaluating the information matrix in linearized DSGE models”, *Economics Letters*, 99(3), 607--610.
- _____ (2010a): “Local identification in DSGE models”, *Journal of Monetary Economics*, 57(2), 189--202.
- _____ (2010b): *On the choice of observables in DSGE models*, mimeo.
- Klein, P. (2000): “Using the generalized Schur form to solve a multivariate linear rational expectations model”, *Journal of Economic Dynamics and Control*, 24(10), 1405--1423, <http://ideas.repec.org/a/eee/dyncon/v24y2000i10p1405-1423.html>.
- Rothenberg, T. J. (1971): “Identification in Parametric Models”, *Econometrica*, 39(3), 577--91, <http://ideas.repec.org/a/ecm/emetrp/v39y1971i3p577-91.html>.
- Sims, C. A. (2002): “Solving Linear Rational Expectations Models”, *Computational Economics*, 20(1-2), 1--20, <http://ideas.repec.org/a/kap/compec/v20y2002i1-2p1-20.html>.