

RESTRIÇÃO FINANCEIRA E DIFERENÇAS REGIONAIS NAS DECISÕES DE INVESTIMENTO DA FIRMA: UMA ABORDAGEM BAYESIANA

Prof. Dr. Aquiles Elie Guimarães Kalatzis - Universidade São Paulo -EESC/USP.

Camila Fernanda Bassetto - Aluna de doutorado do Programa de Pós Graduação de Engenharia de Produção; Universidade São Paulo - EESC/USP.

Prof. Titular Carlos Roberto Azzoni - Universidade São Paulo - FEA/USP.

Resumo

Este estudo procura considerar a questão relacionada ao crescimento regional através das decisões de investimento das firmas privadas. A questão considerada é: será que as firmas decidem sobre o comportamento do investimento da mesma forma em diferentes partes do território brasileiro? Este trabalho investiga o comportamento do investimento de 366 empresas brasileiras no período de 1996-2004. Utilizou-se um modelo econométrico dentro de uma abordagem bayesiana para dados longitudinais com os parâmetros variando por região para identificar diferenças entre elas. Como se trata de uma abordagem bayesiana, deve-se assumir distribuições a priori para os parâmetros; dependendo das prioris atribuídas, o modelo foi classificado como de efeito fixo ou aleatório. A presença de diferenças regionais nas decisões de investimento da firma é uma importante informação a ser considerada na formulação de políticas de desenvolvimento regional. Na comparação dos modelos, foi utilizado o critério das densidades preditivas ordenadas.

Palavras-chave: Decisões de Investimento, Diferenças Regionais, Economia Regional, Abordagem Bayesiana.

Abstract

Most regional programs focus on the supply side of regions, emphasizing attraction conditions offered, such as infrastructure, labor skills, etc. This study analyses one aspect of the demand side, that is, how investment decisions of private firms are made. The question asked is: do corporations decide on investments in the same way in different parts of the territory? This paper analyses investments of 366 large Brazilian firms in the period 1996-2004. We considered a bayesian model with fixed and random effect with normal distributions and with a *t*-student distribution for the region-varying parameters. To compare the models we used the recursive predictive density criterion. The results indicated clear evidence that the firms in different parts not decide on investment in the same way. This is important information for regional development policy, for different mechanisms should be used in different regions in order to foster private investment.

Key-word: Investment Decision, Regional Differences, Regional Economy, Bayesian Approach.

1 - Introdução

A identificação do comportamento das decisões de investimento empresarial tem sido um tema de grande importância na literatura da teoria do investimento, não no que se refere às decisões de orçamento de capital no âmbito da firma, mas principalmente devido à sua relação com o desenvolvimento financeiro e crescimento econômico. A compreensão dos fatores que influenciam e restringem essas decisões torna-se de grande relevância, principalmente para economias em desenvolvimento como o Brasil. De acordo com a teoria econômica, o desenvolvimento dos mercados financeiros pode proporcionar reduções nos custos de transação e informação, influenciando na queda das taxas de captação de recursos e, conseqüentemente, nas decisões de investimentos.

A relação entre desenvolvimento financeiro e crescimento econômico tem sido alvo de pesquisa de diversos autores como King e Levine (1993), Levine (1997), Stiglitz (1990), Hafer e Jensen (1991), Rajan e Zingales (1998), Levine, Loayaza e Beck (2000) entre outros. Nesses estudos, os autores encontraram evidências de uma relação positiva entre o desenvolvimento financeiro, a taxa de acumulação de capital e eficiência econômica. Neste sentido, o tema tem sido de grande relevância, especialmente para as economias emergentes, devido à sua estreita relação com fatores macroeconômicos, políticas públicas, economia industrial, *corporate finance*, possibilitando assim entender os motivos das grandes restrições de financiamento observadas nos mercados de crédito e de capitais.

Embora a análise de decisões de investimento tenha sido tratada na literatura há um longo tempo, o interesse foi renovado com o trabalho de Fazzari, Hubbard e Petersen (1988). Decisões de investimento são complexas e não tão freqüentes quanto outras decisões das firmas, impedindo a formação de regras práticas. A literatura destaca o papel da assimetria de informação no mercado de crédito, fazendo com que as instituições tenham dificuldades em diferenciar entre bons e maus tomadores de recursos (Stiglitz e Weiss, 1981). Gestores das firmas têm mais informações sobre os negócios do que investidores, um fator que poderia conduzir a uma subavaliação no valor da firma e, portanto ao acesso de capital externo. Neste caso, a utilização de fontes externas de recursos pode representar um custo muito elevado. A preferência por fundos internos poderia também depender da taxa sobre os custos da transação. O uso de fundos externos depende dos custos relativos, embora possa proporcionar um aumento da eficiência na gestão dos recursos. Outras fontes de conflitos entre acionistas, gestores e emprestadores de capital, como risco moral, seleção adversa e custo de agência também influenciam no custo da dívida.

Com o objetivo de explicar o comportamento do investimento da firma diferentes estudos têm introduzido variáveis de liquidez reconhecendo o papel dos fundos internos como determinantes do investimento. O modelo da firma representativa é abandonado e dados *cross section* e temporal são utilizados para considerar a heterogeneidade das firmas. Em geral, o investimento é função do fluxo de caixa, dívida, rentabilidade e variáveis específicas pertencendo a diferentes situações. O papel dos diferentes fatores é analisado através de resultados empíricos.

Este artigo está organizado em seções, incluindo essa introdução, enquanto na seção seguinte são apresentados o modelo do investimento e os dados utilizados para analisar o comportamento do investimento em quatro macro regiões. No terceiro item faz-se uma breve descrição do procedimento bayesiano para em seguida, na seção quatro, apresentar as densidades a posteriori para os parâmetros. Na seção cinco realiza-se a seleção de modelos utilizando o critério das densidades preditivas ordenadas. Por fim, nos itens seis e sete é feita a análise dos resultados e a conclusão, respectivamente.

2 – Dados e Modelo

Os dados utilizados neste trabalho referem-se a um conjunto de 366 empresas, no período de 1996 a 2004, separadas por regiões, publicados na revista *Exame – Maiores e Melhores*, e organizado pela Fipecafi – Fundação Instituto de Pesquisas Contábeis, Atuariais e Financeiras, Departamento de contabilidade, Universidade de São Paulo. Dessas 366 empresas, 26 estão localizadas na região Nordeste (NE), 16 na região Centro-Oeste (CO), 226 na região Sudeste (SE) e 98 na região Sul (S).

Para explicar o comportamento do investimento da firma e tentar verificar a presença de restrições financeiras em cada uma das regiões será considerado o modelo dado na expressão abaixo:

$$\left(\frac{I}{K}\right)_{it} = a_i + w_t + b_{1j}\left(\frac{I}{K}\right)_{it-1} + b_{2j}\left(\frac{I}{K}\right)_{it-1}^2 + b_{3j}\left(\frac{FC}{K}\right)_{it} + b_{4j}\left(\frac{V}{K}\right)_{it} + b_{5j}\left(\frac{FIN}{K}\right)_{it} + e_{it} \quad (2.1)$$

onde i representa as firmas, $i = 1, \dots, N$; t é o ano, $t = 1, \dots, T$; $j = 1, \dots, J$ é a região; a_i é o efeito específico da firma, o qual procura contemplar o comportamento peculiar das características não observáveis, por exemplo, a capacidade gerencial; w_t é o componente temporal, que tem por objetivo incorporar o efeito de todas as variáveis observadas e não observadas que não variam entre as firmas, mas que variam entre os anos; K_{it} é o estoque de capital (Ativo Imobilizado); I_{it} é o investimento da firma, definido como $K_{it} - K_{it-1}$; FC_{it} é o fluxo de caixa; V_{it} são as vendas; FIN_{it} é o financiamento total da empresa e e_{it} é o erro. A divisão de todas as variáveis pelo estoque de capital proporciona que o investimento seja medido em taxa, enquanto as outras variáveis são representadas como variações em relação ao estoque de capital.

A variável “fluxo de caixa em proporção ao estoque de capital” procura considerar o efeito de possíveis restrições de liquidez sobre o comportamento do investimento, embora represente também o potencial de rentabilidade futura. A introdução da variável “dívida da empresa em proporção ao estoque de capital” deve-se à idéia referente aos benefícios tributários da dívida e ao fato de que uma maior alavancagem pode elevar o valor da firma. Como apresentados anteriormente, alguns autores sustentam que o grau de alavancagem estaria positivamente relacionado a melhorias na eficiência operacional. A utilização dos valores defasados da variável dependente, juntamente com os valores defasados das preditoras, procura contemplar o aspecto dinâmico do comportamento do investimento. A variável quadrática foi introduzida com o objetivo de refletir a presença de um comportamento não linear no processo de ajustamento do estoque de capital. A razão “vendas sobre o estoque de capital” procura considerar o papel da taxa de mudança esperada no nível de vendas ou nível de produção, conforme princípio inicial do modelo Acelerador, em que o estoque de ativo fixo real da firma é proporcional a alterações positivas na taxa de seu produto.

3 - Abordagem Bayesiana utilizando Dados em Painel

Modelos de dados em painel com efeito fixo ou aleatório têm sido muito utilizados na estimação de parâmetros quando se dispõe de uma amostra com dados em corte transversal (*cross section*) e séries temporais. A vantagem de utilizar dados longitudinais decorre de um maior número de observações, possibilitando maiores informações dos dados, maior grau de liberdade na estimação dos parâmetros e mais eficiência. No entanto, como dados em painel consideram micro unidades, por exemplo, indivíduos, empresas, países, etc., torna-se mais propenso a presença de muita heterogeneidade.

A estimação por dados em painel, neste caso, considera explicitamente essas variáveis individuais por meio da introdução de um efeito específico. A introdução nesses modelos de um efeito específico da firma e temporal tem por finalidade considerar efeitos não observados. Enquanto o efeito específico da firma procura contemplar o comportamento peculiar das características não observáveis, por exemplo, capacidade gerencial, que são específicas a cada firma e constantes no tempo, o componente temporal procura incorporar o efeito de todas as variáveis observadas e não observadas que não variam entre as firmas, mas que variam entre anos.

A escolha entre o modelo de efeito fixo e efeitos aleatórios normalmente não é uma questão muito simples. A estimação pelo método do componente estocástico permite fazer inferência sobre a população como um todo, diferentemente do modelo de efeito fixo, em que a inferência restringe-se somente às empresas da amostra. Por outro lado, no modelo de efeitos aleatórios não se admite a possibilidade de correlação entre os efeitos específicos da firma e as variáveis explicativas, distintamente do modelo de efeito fixo em que esta hipótese é possível. Embora o modelo de componente estocástico permita fazer inferências para toda população, o que aparentemente poderia ser mais interessante, o estimador de efeito fixo pode ser mais apropriado quando se trata de dados econômicos. A razão é que o componente específico da firma, por exemplo, capacidade gerencial afeta de alguma forma a gestão do capital próprio e a forma de alavancagem financeira e, conseqüentemente, as decisões de investimento da firma. Nesse caso, a estimação pelo método dos efeitos aleatórios desconsiderando-se tal correlação poderia conduzir a estimadores inconsistentes.

No modelo de efeito fixo assumindo a seguinte forma:

$$y_{it} = a_i + w_t + d y_{it-1} + X'_{it} b + e_{it}, \quad (3.1)$$

onde a_i é considerado o efeito específico da firma i , e w_t é o efeito temporal não observado, tem-se que:

$$(y_{it} - \bar{y}_{it}) = d (y_{it-1} - \bar{y}_{it-1}) + b (x_{it} - \bar{x}_{it}) + (e_{it} - \bar{e}_{it}), \quad (3.2)$$

onde $\bar{y}$, $\bar{x}$ e $\bar{e}$ são os valores médios. Essa transformação que elimina o efeito fixo irá trazer como consequência um regressor correlacionado com os erros, isto é, $E[(e_{it} - \bar{e}_{it-1}) / (y_{it-1} - \bar{y}_{it-2})] \neq 0$ tornando, assim, o estimador viesado ou até mesmo inconsistente. Esta correlação surge em função da transformação do modelo para eliminar os efeitos específicos da firma e o efeito temporal devido a um curto período de tempo, mesmo quando $N \rightarrow \infty$.

Experimentos via simulações MCMC realizadas por Hsiao, Pesaran e Tahmiscioglu (1997) para diferentes modelos mostraram que o estimador bayesiano hierárquico apresentou

o melhor desempenho entre todos, isto é, o menor viés, mesmo por um período curto de tempo. Para os autores, “*Since the comparison of alternative estimators in this study in undertaken to a large extent using the sampling properties of estimators, econometricians who adopt the sampling theory framework should find the Bayesian approach more attractive in the light of our findings*” (p. 26). Nas simulações realizadas para os diversos modelos, os autores utilizaram um período temporal de 5 e 20, e o menor viés foi para o modelo bayesiano hierárquico, mesmo com um $T = 5$, inferior ao utilizado neste estudo.

A estimação e inferências sobre os parâmetros na abordagem bayesiana provêm de duas fontes de informações: uma contida nos dados y sobre os parâmetros de interesse q , e outra denominada de informação prévia, não representada pelos dados. Na abordagem bayesiana, o processo que especifica a estrutura probabilística, isto é, o processo gerador de dados (DGP) da variável dependente como função das covariadas é composto por duas funções: uma indicando o conhecimento a priori representado pela distribuição de probabilidade, denotada por $p(q)$, e outra representando a distribuição das informações contidas nos dados, denotada por $f(y/q)$, isto é, a função verossimilhança dos parâmetros. Através da combinação de ambas as informações obtém-se a função densidade de probabilidade a posteriori, denotada por:

$$p(q/y) = \frac{f(y/q)p(q)}{p(y)} \propto p(q) \cdot f(y/q) \quad (3.3)$$

onde $p(q/y)$ é a função densidade a posteriori, e o primeiro termo do lado direito mostra o produto da priori $p(q)$ pela verossimilhança condicionada sobre os dados $f(y/q)$. A partir da distribuição a posteriori, é possível fazer inferência sem perda de informação. O termo $p(y)$, omitido no segundo termo do lado direito de (3.3), é considerado como um fator de normalização, o qual, como não depende de q com y fixo, pode ser considerado uma constante. O papel da constante normalizadora é evitar que a densidade a posteriori seja imprópria, isto é, $\int p(q) dq \neq 1$. A fórmula dada em (3.3) é conhecida como fórmula de Bayes, indicando que a distribuição a posteriori é proporcional ao produto da priori pela verossimilhança. Como normalmente o interesse é computar cada parâmetro individualmente, deve-se calcular a densidade marginal a posteriori de cada parâmetro de interesse, condicionada aos demais parâmetros.

Uma característica fundamental na abordagem bayesiana é que os parâmetros a serem estimados são tratados como aleatórios e não como quantidades fixas, e muitas vezes não são considerados como totalmente desconhecidos. O grau de incerteza quanto aos parâmetros é representado pela distribuição de probabilidade denominada de priori, cujo objetivo é proporcionar a introdução do conhecimento prévio na estimação dos parâmetros.

O método para escolher a densidade a priori pode ser baseado na determinação da probabilidade de forma subjetiva ou objetiva. No primeiro caso, considera-se uma situação em que não se tem qualquer conhecimento sobre a distribuição de probabilidade a priori. Isso significa que as densidades a priori têm como base a opinião pessoal do pesquisador, sua intuição, opinião de especialistas etc. No caso do método objetivo, com ou sem nenhuma informação prévia, seria possível atribuir uma distribuição de probabilidade a priori. Na hipótese de nenhuma informação, utilizar-se-ia uma priori não-informativa. Muitas vezes, utiliza-se uma priori vaga ou difusa na hipótese de que quase nenhuma informação possa ser utilizada previamente. Nesse caso, tem-se utilizado uma distribuição a priori uniforme, em que todos os valores possíveis para q são igualmente prováveis, ou, ainda, uma distribuição

normal com uma variância muito grande. Quando se trata de estimar vetores de parâmetros, como em modelos bayesianos, freqüentemente pode-se empregar distribuições de forma hierárquica, em que a especificação da distribuição a priori é considerada em dois estágios, sendo o primeiro estágio definido pela distribuição a priori dos parâmetros $p(q/l)$ e o segundo pela distribuição a priori dos hiperparâmetros $p(l)$ ¹. Esse procedimento hierárquico pode ser especificado pelo modelo bayesiano cujo interesse é dado por $p(q)$ de forma que:

$$p(q) = \int p(q/l)p(l)dl, \quad (3.4)$$

onde o parâmetro q representa o primeiro estágio na estrutura hierárquica e l , denominado de hiperparâmetro, representa o segundo estágio. Teoricamente não haveria um limite para o número de estágios, porém à medida que aumenta o número de estágios, tornam-se mais complexas a especificação dos hiperparâmetros e a sua interpretação. O cálculo da densidade a posteriori em muitas ocasiões pode ser inviável, devido a um complexo processo no cálculo das integrais. Nesses casos, quando as integrais não podem ser calculadas analiticamente, aproximações por meio de métodos numéricos devem ser utilizadas.

As densidades a posteriori para os parâmetros em questão podem ser calculadas utilizando-se algoritmos de simulação pelo método de Monte Carlo por Cadeia de Markov (MCMC). Esse método é uma técnica de simulação iterativa baseado em cadeias de Markov que gera uma amostra da distribuição a priori e calcula as estimativas amostrais caracterizadas por esta distribuição. Quando a dimensão do vetor aleatório for muito grande, a integração para obter as densidades marginais de cada parâmetro torna-se inviável. Neste caso, uma alternativa é a utilização do método de amostragem *Gibbs Sampling*, que é um método de simulação de distribuições cujos vetores aleatórios são particionados em blocos, em que se define densidade de transição como o produto das densidades condicionais completas, as quais são necessárias terem formas “conhecidas”. A convergência é alcançada quando se atinge uma distribuição estacionária ou de equilíbrio, que é a distribuição de interesse.

O método de amostragem *Gibbs* é utilizado na geração de amostras quando as densidades condicionais a posteriori apresentam uma forma conhecida. Na ausência de distribuições conhecidas, utiliza-se o *Metropolis-Hasting*². Esse algoritmo permite atingir as densidades a posteriori de uma distribuição de interesse ou de equilíbrio p através da construção de uma cadeia de Markov. Um aspecto interessante é que não é necessário conhecer a forma completa de p , que só interfere no algoritmo através da razão de teste. Embora todos os valores candidatos sejam ponderados igualmente, nem todos são aceitos. Neste sentido, a verificação da convergência das densidades a posteriori pelo algoritmo *Gibbs* torna-se fundamental para inferências seguras sobre os parâmetros de interesse.

A convergência da amostra gerada pode ser verificada formalmente pelo método proposto por Gelman e Rubin (1952). Os autores propuseram um método de simulação baseado em várias cadeias de Markov geradas a partir de vários pontos iniciais. Na seção seguinte são apresentadas as densidades a posteriori dos parâmetros do modelo.

4 - Densidades a Posteriori para os Parâmetros do Modelo

Neste item, são apresentadas as densidades a posteriori para cada parâmetro do modelo. Como se trata de um modelo bayesiano, na estimação dos parâmetros de interesse é

¹ Os hiperparâmetros são utilizados para expressar a incerteza sobre as prioris dos parâmetros.

² A origem desse nome é decorrência dos artigos de Metropolis et al. (1953) e Hasting (1970).

necessário especificar a distribuição a priori. Uma vez definida a distribuição a priori e a função de verossimilhança e combinadas as duas, obtém-se a densidade a posteriori de cada parâmetro. O modelo dado na expressão (3.1) inicialmente será considerado como sendo de efeito fixo e, depois de efeito aleatório. Em cada um dos casos, considerou-se uma distribuição normal para o erro e, em seguida, uma *t* de *student* com 5 graus de liberdade. A justificativa para o uso desta segunda distribuição pode ser encontrada em Koop (2003) onde é apontado que “*if a Normal distribution is too restrictive, you can a more flexible distribution by taking a weighted average of more the one Normal distribution*”. A abordagem bayesiana foi considerada na estimação dos parâmetros do modelo, os quais estão variando por região. Para obter tais estimativas, o software Winbugs (Spiegelhalter, 1995) foi utilizado. A convergência dos valores estimados pôde ser verificada pelo índice de Gelman e Rubin (1952).

Quando o modelo de efeito fixo é considerado, distribuições uniformes são atribuídas a priori para os efeitos específico e temporal. Dessa forma, as distribuições a priori para os parâmetros do modelo são especificadas em um único estágio. No modelo de efeito aleatório, é assumido que os efeitos a_i e w_t são distribuídos seguindo distribuições normais com variâncias desconhecidas, exigindo que as prioris sejam especificadas em dois estágios, ou seja, uma estrutura hierárquica. Segundo Koop (2003), “*Bayesian Analysis with such a non-hierarchical prior leads to a model which is analogous to the fixed effects models*” (p.151).

Para facilitar a notação utilizada nas expressões referentes às distribuições de probabilidade, utiliza-se a seguinte equivalência:

$$(I/K)_{it} = Y_{it}, \quad (I/K)_{it-1} = X_{1it}, \quad (I/K)_{it-1}^2 = X_{2it}, \quad (FC/K)_{it} = X_{3it}, \quad (V/K)_{it} = X_{4it}, \\ (FIN/K)_{it} = X_{5it}.$$

Usando-se a equivalência introduzida acima, o modelo dado em (3.1) pode ser escrito da forma:

$$Y_{it} = a_i + w_t + b_{1j}X_{1it} + b_{2j}X_{2it} + b_{3j}X_{3it} + b_{4j}X_{4it} + b_{5j}X_{5it} + e_{it} \quad (4.1)$$

As densidades a posteriori para os modelos de efeito fixo e aleatório com uma distribuição normal e *t* de *student* para o erro são definidas a seguir.

4.1 - Modelo de efeito fixo

Quando uma distribuição normal para o erro do modelo dado em (3.1), considerando-o como sendo de efeito fixo, as distribuições a priori são especificadas em um único estágio da seguinte forma:

$$\begin{aligned} (i) \quad & a_i \sim U(e_1, f_1); \quad e_1, f_1 \text{ conhecidos, } i = 1, 2, \dots, 366; \\ (ii) \quad & w_t \sim U(e_2, f_2); \quad e_2, f_2 \text{ conhecidos, } t = 1, 2, \dots, 8; \\ (iii) \quad & b_{lj} \sim N(a_{lj}, b_{lj}^2); \quad a_{lj}, b_{lj} \text{ conhecidos; } l = 1, 2, \dots, 5; j = 1, \dots, 4; \\ (iv) \quad & s^2 \sim IG(c, d); \quad c, d \text{ conhecidos.} \end{aligned} \quad (4.2)$$

$U(d, f)$ denota uma distribuição uniforme, $N(m, s^2)$ representa uma distribuição normal e $IG(x, y)$ representa uma distribuição gama inversa.

Considerando as prioris definidas em (4.2) independentes e combinando-as entre si, obtém-se a distribuição a priori conjunta dos parâmetros do modelo. Computando-se a

distribuição a priori conjunta com a função de verossimilhança, encontra-se a posteriori conjunta dada por:

$$p\left(\underset{\sim}{a}, \underset{\sim}{b}, \underset{\sim}{w}, s^2 / \underset{\sim}{y}, \underset{\sim}{x}\right) \propto \frac{1}{f_1 - e_1} \cdot \frac{1}{f_2 - e_2} \cdot \prod_{l=1}^5 \prod_{j=1}^4 \exp\left\{-\frac{1}{2b_{lj}^2} (b_{lj} - a_{lj})^2\right\} \cdot (s^2)^{-(c+1)} \exp\left\{-\frac{d}{s^2}\right\} \cdot (s^2)^{-\frac{NT}{2}} \exp\left\{-\frac{1}{2s^2} \sum_{i=1}^N \sum_{t=1}^T (e_{it})^2\right\} \quad (4.3)$$

onde

$$e_{it} = Y_{it} - a_i - w_t - b_{1j}X_{1it} - b_{2j}X_{2it} - b_{3j}X_{3it} - b_{4j}X_{4it} - b_{5j}X_{5it} \quad (4.4)$$

Assumindo uma distribuição *t* de *student*, as prioris atribuídas aos parâmetros são análogas às anteriores. A posteriori conjunta é dada por:

$$p\left(\underset{\sim}{a}, \underset{\sim}{b}, \underset{\sim}{w}, s^2 / \underset{\sim}{y}, \underset{\sim}{x}\right) \propto \frac{1}{f_1 - e_1} \cdot \frac{1}{f_2 - e_2} \cdot \prod_{l=1}^5 \prod_{j=1}^4 \exp\left\{-\frac{1}{2b_{lj}^2} (b_{lj} - a_{lj})^2\right\} \cdot (s^2)^{-(c+1)} \exp\left\{-\frac{d}{s^2}\right\} \cdot \prod_{i=1}^N \prod_{t=1}^T \frac{1}{\sqrt{psk}} \left[1 + \frac{(e_{it})^2}{ks^2}\right]^{-\left(\frac{k+1}{2}\right)} \quad (4.5)$$

4.2 - Modelo de efeito aleatório

Assumindo-se uma distribuição normal para o erro do modelo dado em (2.1), considerando-o como sendo de efeito aleatório, as distribuições a priori possuem uma estrutura hierárquica, pois são especificadas em dois estágios, como dado abaixo:

1º estágio:

- (i) $a_i \sim U(e_1, f_1)$; e_1, f_1 conhecidos, $i = 1, 2, \dots, 366$;
 - (ii) $w_t \sim U(e_2, f_2)$; e_2, f_2 conhecidos, $t = 1, 2, \dots, 8$;
 - (iii) $b_{lj} \sim N(a_{lj}, b_{lj}^2)$; a_{lj}, b_{lj} conhecidos; $l = 1, 2, \dots, 5$; $j = 1, \dots, 4$;
 - (iv) $s^2 \sim IG(c_1, d_1)$; c_1, d_1 conhecidos.
- (4.6)

2º estágio:

- (v) $s_a^2 \sim IG(c_2, d_2)$; c_2, d_2 conhecidos;
 - (vi) $s_w^2 \sim IG(c_3, d_3)$; c_3, d_3 conhecidos.
- (4.7)

Considerando todas as distribuições a priori definidas em (4.6) e (4.7) independentes e combinando-as entre si, obtém-se a distribuição a priori conjunta dos parâmetros do modelo. Computando-se a distribuição a priori conjunta com a função de verossimilhança, encontra-se a posteriori conjunta:

$$\begin{aligned}
p\left(\tilde{a}, \tilde{b}, \tilde{w}, s^2, s_a^2, s_w^2 / \tilde{y}, \tilde{x}\right) &\propto \prod_{i=1}^N \frac{1}{\sqrt{2ps_a^2}} \exp\left\{-\frac{a_i^2}{2s_a^2}\right\} \prod_{t=1}^T \frac{1}{\sqrt{2ps_w^2}} \exp\left\{-\frac{w_t^2}{2s_w^2}\right\} \\
&\prod_{l=1}^5 \exp\left\{-\frac{1}{2b_{lj}^2}(b_{lj} - a_{lj})^2\right\} \cdot (s^2)^{-(c_1+1)} \exp\left\{-\frac{d_1}{s^2}\right\} \cdot (s_a^2)^{-(c_2+1)} \exp\left\{-\frac{d_2}{s_a^2}\right\} \\
&\cdot (s_w^2)^{-(c_3+1)} \exp\left\{-\frac{d_3}{s_w^2}\right\} \cdot (s^2)^{-\frac{NT}{2}} \exp\left\{-\frac{1}{2s^2} \sum_{i=1}^N \sum_{t=1}^T (e_{it})^2\right\}
\end{aligned} \quad (4.8)$$

Considerando uma distribuição t de *student* e as priors definidas anteriormente em dois estágios, dados por (4.6) e (4.7), a posteriori conjunta é dada por:

$$\begin{aligned}
p\left(\tilde{a}, \tilde{b}, \tilde{w}, s^2, s_a^2, s_w^2 / \tilde{y}, \tilde{x}\right) &\propto \prod_{i=1}^N \frac{1}{\sqrt{2ps_a^2}} \exp\left\{-\frac{a_i^2}{2s_a^2}\right\} \prod_{t=1}^T \frac{1}{\sqrt{2ps_w^2}} \exp\left\{-\frac{w_t^2}{2s_w^2}\right\} \\
&\prod_{l=1}^5 \exp\left\{-\frac{1}{2b_{lj}^2}(b_{lj} - a_{lj})^2\right\} \cdot (s^2)^{-(c_1+1)} \exp\left\{-\frac{d_1}{s^2}\right\} \cdot (s_a^2)^{-(c_2+1)} \exp\left\{-\frac{d_2}{s_a^2}\right\} \\
&\cdot (s_w^2)^{-(c_3+1)} \exp\left\{-\frac{d_3}{s_w^2}\right\} \cdot \prod_{i=1}^N \prod_{t=1}^T \frac{1}{\sqrt{psk}} \left[1 + \frac{(e_{it})^2}{ks^2}\right]^{-\left(\frac{k+1}{2}\right)}
\end{aligned} \quad (4.9)$$

Na seleção do modelo de efeito fixo ou aleatório, assumindo uma distribuição normal e uma t de *student* para o erro em ambos é realizada pelo critério das preditivas ordenadas, juntamente com a estimação dos parâmetros e a análise econômica dos resultados.

5 - Seleção e Discriminação de Modelos

A seleção de modelos foi feita utilizando o critério das densidades preditivas ordenadas. Outros critérios como Fator de Bayes e BIC (*Bayes Information Criterion*) têm sido freqüentemente utilizados na discriminação de modelos. No entanto, como o Fator de Bayes é altamente sensível à escolha da priori, principalmente a uma priori difusa, e ao numero de parâmetros, e o BIC apresenta uma tendência de escolha de modelos mais simples, optou-se pelo critério das densidades preditivas ordenadas³.

Na seleção de modelos pelo critério das densidades preditivas ordenadas, escolhe-se o modelo que melhor explica os dados, isto é, aquele que apresentar o maior valor de predição para as observações futuras. Neste caso, considera-se a probabilidade sobre os valores observados preditivamente, isto é, a escolha de uma preditor pontual para Y é realizada de acordo com uma função perda possível de ocorrência. Para Gamerman (1997), esta abordagem apresenta uma vantagem quando se considera “que ela permite julgamentos que não são ambíguos tendo, portanto, um sentido claro e inquestionável. Uma previsão é sempre confrontável com a realidade ao passo que a estimação nunca o é” (p. 167). O critério de seleção de modelos baseado nas preditivas ordenadas a posteriori é implementado pelo método de simulação Monte Carlo por Cadeia de Markov (Gelfand e Dey, 1993).

³ Maiores detalhes sobre a sensibilidade da escolha de uma priori difusa, do número de parâmetros incidentes no Fator de Bayes, e sobre a tendência de escolha de uma modelo mais simples quando se utiliza o BIC, podem ser encontrados em Kass (1992), Gelfand e Day (1993), Kass e Raftery (1995) e Weakliem (1999).

A densidade preditiva para o modelo dado o vetor $y_{(it)}$, é:

$$c_{it}(m) = f(y_{it} / y_{(it)}, x_{lit}) = \int \dots \int f(y_{it} / q, x_{lit}) p(q / y_{(it)}, x_{l(it)}) dq, \quad (5.1)$$

para $i = 1, \dots, N$; $t = 1, \dots, T$; $m = 1, \dots, M$, q indica o vetor de parâmetros, $y_{(it)}$ representa a matriz resposta sem a observação referente a i -ésima firma t -ésimo ano e $x_{l(it)}$ são as matrizes dos dados correspondentes às variáveis do modelo, exceto para a i -ésima firma no t -ésimo ano.

A partir das amostras geradas pelo algoritmo de *Gibbs Sampling*, a densidade em (5.1) pode ser aproximada pela estimativa de Monte Carlo como:

$$\hat{c}_{it}(m) = \hat{f}(y_{it} / y_{(it)}, x_{lit}) = \frac{1}{S} \sum_{s=1}^S f(y_{it} / q^{(s)}, x_{lit}), \quad (5.2)$$

onde S é o número de amostras geradas pelo método de amostragem de *Gibbs*.

A comparação de modelos pelo método das densidades preditivas ordenadas é feita utilizando-se um índice dado por: $c(m) = \prod_{i=1}^N \prod_{t=1}^T \hat{c}_{it}(m)$, onde $c(m)$ é a densidade preditiva ordenada para o modelo m .

Tabela 5.1 - Critério de seleção de modelos

Critério	Efeito Fixo		Efeito Aleatório	
	Normal	t de <i>student</i>	Normal	t de <i>student</i>
DPO	7713.0556	281.1674	7651.4853	498.264

Observa-se pela tabela 5.1 que o modelo de efeito fixo assumindo uma distribuição normal para o erro apresenta o maior valor segundo o critério da densidade preditiva ordenada, sendo, portanto, o modelo preferível e tomado como referência para análise dos parâmetros.

6 – Resultados

Considerando as questões apontadas nos itens anteriores, esta seção busca analisar, a partir do ponto de vista econômico, os principais resultados obtidos da estimação dos parâmetros da equação 2.1.

A tabela 6.1 apresenta os principais indicadores financeiros das firmas agrupadas por macro regiões. A variável “investimento como razão do estoque de capital” apresenta pouca diferença para as regiões. A variável “fluxo de caixa como razão do estoque de capital” apresenta seu maior valor para a região Centro-Oeste e menor valor para a região Nordeste. Já a variável “vendas como razão do estoque de capital” apresenta valores semelhantes para as regiões SE, S e NE, enquanto o seu valor para a região NE é bem inferior a demais. Com relação à variável “dívida como razão do estoque de capital”, a região Sudeste exibe o maior valor. No entanto, quando se utiliza a “dívida em relação patrimônio líquido” o maior grau de alavancagem financeira é da região Sul, indicando uma clara dependência de capital de terceiros.

Tabela 6.1 - Características das Firms por Macro Regiões – Valores Médios

Variáveis	Regiões				
	Amostra	NE	CO	SE	S
Investimento/Estoque de Capital	0.440	0.360	0.460	0.459	0.409
Fluxo de caixa/Estoque de Capital	0.548	0.370	0.808	0.588	0.487
Vendas/Estoque de Capital	8.04	3.81	6.51	8.258	8.614
Dívida/Estoque de Capital	1.037	0.746	0.830	1.204	0.775
D Vendas/Estoque de Capital	0.325	0.351	0.312	0.333	0.307
CCL/Estoque de Capital	1.264	0.678	1.816	1.306	1.265
Lucro líquido/Estoque de Capital	0.371	0.241	0.631	0.393	0.333
Lucro líquido/ Patrimônio líquido	-0.129	-0.428	0.162	0.0010	-0.411
Divida/Patrimônio líquido	1.319	0.943	0.358	0.786	2.879
Índice de liquidez	1.94	1.77	2.382	1.969	1.87
(I/K)/(FC/K)	3.721	-0.326	8.083	4.696	1.241
(I/K)/(LL/K)	2.426	1.22	8.18	2.146	2.594
(I/K)/(IL)	0.329	0.263	0.283	0.358	0.283
N. de Firms	366	26	16	226	98

* (I/K) é Investimento/Estoque de Capital; (CCL/K) é o Capital Circulante Líquido; (FC/K) é Fluxo de caixa/ Estoque de Capital; (LL/K) é Lucro líquido/ Estoque de Capital e IL é o índice de liquidez das firms. As razões dessas variáveis representam indicadores de necessidade de caixa.

As empresas da região Nordeste apresentam as maiores dificuldades financeiras, isto é, além de indicar baixo nível de vendas, baixo endividamento quando ponderado pelo estoque de capital e menor nível de capital de giro, exibe também um “lucro líquido sobre o patrimônio líquido” negativo. A fragilidade financeira das firms da região Nordeste também pode ser verificada pelos indicadores de folga de caixa, indicado nas últimas três linhas da tabela 6.1. As firms dessa região apresentam os menores níveis de folga de caixa e um valor negativo para a taxa de investimento em relação o fluxo de caixa como razão do estoque de capital necessário para novos empreendimentos.

O reduzido nível de caixa como razão do estoque de capital diante de uma demanda de investimento semelhante às outras regiões indica uma grande necessidade de capital externo para que tal demanda seja atendida. Essa necessidade de capital externo parece pouco atendida quando se observa que o grau de endividamento dessas empresas medido pela dívida sobre o patrimônio líquido é menor que das firms pertencentes às outras regiões, as quais poderiam ser consideradas como irrestritas financeiramente, já que apresentam alta disponibilidade de caixa e elevado níveis de vendas. Por outro lado, quando se considera a variável ‘lucro líquido como razão do patrimônio líquido’, nota-se que as regiões Nordeste, Sudeste e Sul não estariam sujeitas à crítica de que o parâmetro estimado do fluxo de caixa, sendo significativo, pudesse estar atuando como uma *proxy* para a rentabilidade futura da firma. Nesse caso, as firms dessas regiões poderiam ser consideradas restritas financeiramente.

A tabela 6.2 mostra os parâmetros estimados para cada macro região considerando dois modelos: efeito fixo e aleatórios, ambos assumindo uma distribuição normal e uma *t* de *student* para erro. Embora o modelo com uma distribuição *t* de *student* considere a

presença de heterocedasticidade, sendo mais apropriado, o modelo de efeito fixo variando os parâmetros por região e considerando uma distribuição normal para o erro foi o modelo preferível segundo o critério das preditivas ordenadas.

O parâmetro do fluxo caixa como razão do estoque de capital apresentou-se estatisticamente significativo para as quatro regiões, porém com sinal negativo somente para a região Nordeste. Embora o parâmetro seja significativo para todas as regiões, não se pode afirmar que existe a presença de restrição financeira para a região CO, já que o parâmetro do fluxo de caixa estaria indicando lucratividade futura, devido ao nível de rentabilidade das empresas dessa região. As empresas dessa região também apresentam os maiores níveis de folga de caixa, de 8.18, enquanto o segundo maior valor é de 2.59, referente à região Sul. Por outro lado, as regiões NE, SE e S não estariam sujeitas a tal crítica, já que não indicam que a variável fluxo de caixa esteja atuando como expectativa de lucratividade futura. Isto pode ser observado pelo reduzido nível de rentabilidade da região SE, com um valor próximo de zero para o lucro líquido como razão do patrimônio líquido e, valores negativos para as regiões Nordeste e Sudeste.

Embora o indicador de rentabilidade para as firmas das regiões Sul e Sudeste não indiquem potencial de rentabilidade futura, é difícil caracterizar tais firmas como frágeis financeiramente. Seus bons indicadores financeiros referente a vendas, mais que o dobro da região Nordeste, maiores folgas de caixa e “capital circulante líquido como razão do estoque de capital” maior que a unidade indicam boas condições de liquidez. Neste caso, mesmo considerando que tais firmas sejam consideradas como restritas financeiramente, a razão para a construção de um folga financeira estaria no conhecimento dessa empresas de que a construção de uma folga de caixa poderia reduzir possíveis perdas de oportunidades de novos empreendimentos, como apontam os estudos de Campelo e Weisbach (2004), Booth e Cleary (2006) e Khurana e Pereira e Martin (2006).

A região NE apresentou o maior coeficiente para o fluxo de caixa e negativo de -0.41, indicando que o investimento é negativamente sensível ao fluxo de caixa, além de apresentar do pior indicador de rentabilidade, de -0.428. A presença do sinal negativo para o parâmetro do fluxo de caixa pode estar sinalizando que as firmas dessa região estariam vendendo ativos para fazer frente a forte necessidade de caixa. Um fator que pode estar influenciando significativamente a maior sensibilidade do investimento ao fluxo de caixa negativamente para as firmas dessa região, refere-se ao baixo e, substancialmente menor valor encontrado para a variável de folga financeira, $[(I/K)/(FC/K)]$ igual a -0.326, indicando uma elevada necessidade de caixa.

O parâmetro da variável “dívida sobre o estoque e capital” não se mostrou estatisticamente significativo para explicar o investimento das empresas pertencentes a região Nordeste, apesar das firmas dessa região indicarem que o investimento é sensível ao fluxo de caixa. Tal fato pode estar indicando que as firmas dessa região estariam com dificuldade de acesso a crédito externo para realizar novos investimentos, dependendo assim, mais fortemente de recursos internos. Assim, tais firmas podem ser consideradas restritas segundo Kaplan e Zingales (2000), já que a fragilidade financeira pode ser considerada uma forma de restrição financeira. Por outro lado, para as firmas pertencentes às outras regiões CO, SE e S, o endividamento mostrou-se significativo para explicar o investimento.

Tabela 6.2 - Parâmetros Estimados por Região

Parâmetro	Efeito Fixo						Efeito Aleatório					
	normal	desvio padrão	95% HPDI	<i>t</i> de student	desvio padrão	95% HPDI	normal	desvio padrão	95% HPDI	<i>t</i> de student	desvio padrão	95% HPDI
b_{11}	0.04	0.25	(-0.447; 0.512)	-0.04	0.12	(-0.263; 0.2)	0.05	0.23	(-0.405; 0.512)	0.0032	0.1	(-0.199; 0.209)
b_{12}	-0.13	0.22	(-0.553; 0.298)	-0.22	0.1	(-0.415; -0.025)	-0.04	0.21	(-0.459; 0.374)	-0.1161	0.09	(-0.299; 0.062)
b_{13}	-0.1	0.06	(-0.213; 0.0119)	-0.06	0.03	(-0.114; -0.013)	-0.02	0.06	(-0.13; 0.095)	0.0225	0.02	(-0.024; 0.069)
b_{14}	-0.32	0.07	(-0.448; -0.186)	-0.3	0.05	(-0.403; -0.198)	0.64	0.06	(0.519; 0.756)	0.6022	0.03	(0.539; 0.665)
b_{21}	-0.07	0.1	(-0.26; 0.127)	7.1E-4	0.05	(-0.093; 0.094)	-0.05	0.1	(-0.248; 0.14)	-0.0169	0.04	(-0.106; 0.071)
b_{22}	-0.005	0.07	(-0.132; 0.124)	0.05	0.03	(-0.009; 0.114)	-0.005	0.06	(5.74E-4; -0.006)	0.0299	0.03	(-0.03; 0.089)
b_{23}	-9.8E-4	0.008	(-0.017; 0.015)	0.007	0.004	(-6.89E-4; 0.014)	-0.004	0.008	(9.95E-5; -0.004)	-0.0039	0.003	(-0.011; 0.003)
b_{24}	0.03	0.01	(0.003; 0.05)	0.04	0.01	(0.019; 0.055)	-0.09	0.01	(-0.112; -0.069)	-0.0767	0.007	(-0.089; -0.063)
b_{31}	0.13	0.07	(-0.011; 0.265)	0.02	0.03	(-0.047; 0.085)	0.11	0.07	(-0.032; 0.248)	0.0061	0.03	(-0.058; 0.069)
b_{32}	-0.41	0.11	(-0.621; -0.2)	-0.04	0.06	(-0.166; 0.084)	-0.39	0.1	(-0.595; -0.191)	-0.05	0.06	(-0.170; 0.068)
b_{33}	0.05	0.02	(0.021; 0.085)	0.02	0.01	(4.69E-4; 0.036)	0.05	0.02	(0.016; 0.08)	0.0173	0.009	(1.22E-4; 0.034)
b_{34}	0.06	0.02	(0.013; 0.105)	0.03	0.01	(0.005; 0.06)	0.09	0.02	(0.045; 0.137)	0.0455	0.02	(0.015; 0.076)
b_{41}	-4.0E-5	0.009	(-0.018; 0.018)	0.007	0.004	(-8.6E-4; 0.015)	5.57E-4	0.008	(-0.016; 0.017)	0.0068	0.004	(-3.41E-4; 0.014)
b_{42}	0.01	0.007	(-0.003; 0.025)	0.009	0.004	(1.74E-4; 0.016)	0.01	0.007	(0.001; 0.028)	0.0067	0.004	(-0.001; 0.014)
b_{43}	-3.5E-4	0.002	(-0.005; 0.004)	0.004	0.001	(0.001; 0.006)	-0.002	0.002	(2.38E-5; -0.002)	0.0035	0.001	(0.001; 0.006)
b_{44}	0.01	0.003	(0.005; 0.016)	0.003	0.001	(1.4E-4; 0.006)	0.01	0.003	(0.009; 0.019)	0.006	0.001	(0.003; 0.009)
b_{51}	0.05	0.05	(-0.052; 0.151)	0.02	0.03	(-0.031; 0.081)	0.04	0.05	(-0.056; 0.141)	0.0179	0.03	(-0.031; 0.07)
b_{52}	0.25	0.07	(0.112; 0.379)	0.05	0.04	(-0.04; 0.133)	0.26	0.06	(0.14; 0.378)	0.073	0.04	(-0.008; 0.151)
b_{53}	0.12	0.01	(0.096; 0.141)	0.02	0.007	(0.001; 0.028)	0.12	0.01	(0.094; 0.138)	0.0177	0.007	(0.005; 0.031)
b_{54}	0.05	0.01	(0.024; 0.077)	-0.01	0.009	(-0.026; 0.009)	0.6	0.01	(0.032; 0.086)	-0.0032	0.01	(1.79E-4; -0.004)
s^2	0.44	0.01	(0.416; 0.469)	0.07	0.003	(0.068; 0.082)	0.5	0.02	(0.467; 0.53)	0.0847	0.004	(0.078; 0.092)

* O segundo subscrito dos parâmetros 1, 2, 3 e 4 referem-se às regiões NE, CO, SE e S, respectivamente. No modelo com uma distribuição *t* utilizou-se uma grau de liberdade igual a cinco.

O modelo preferível pela densidade preditiva ordenada, de efeito fixo, assumindo uma distribuição normal indicou que os parâmetros da variável “vendas como razão do estoque de capital” não se apresentaram estatisticamente significativos para explicar o comportamento do investimento. Esta variável não se apresentou estatisticamente significativa para nenhuma região para explicar as decisões de investimento, embora como indicador financeiro tenha apresentado altos valores para as quatro regiões (tabela 6.1). Neste sentido, a idéia inicial do modelo Acelerador de que o estoque de ativo fixo real da firma é proporcional a modificações positivas na taxa de variações no produto não se mostrou válida para o modelo selecionado.

7 - Conclusão

Este trabalho analisou o comportamento do investimento de firmas privadas pertencentes as quatro grandes regiões do território brasileiro e considerando possíveis fontes de diferenças regionais nas decisões de investimentos das firmas. Procurou-se realizar uma breve discussão dos fatores que tradicionalmente afetam as decisões de investimento da firma associado a possíveis fatores regionais. Baseado em uma amostra de 366 firmas, estimou-se uma versão do modelo Acelerador de investimento sob uma abordagem bayesiana com os parâmetros variando por região, considerando efeitos fixo e aleatório e, assumindo uma distribuição normal e uma distribuição *t* de *student* para o erro. Como critério de seleção de modelo utilizou-se a densidade preditiva ordenada, o qual indicou que o modelo de efeito fixo com uma distribuição normal para o erro foi o preferível.

O principal resultado do presente trabalho indica a presença de restrição financeira para as regiões Nordeste, Sudeste e Sul, porém com um maior coeficiente e negativo para as firmas pertencentes à região NE. A estimação dos parâmetros associado aos indicadores financeiros das firmas agrupadas por região indica que a maior sensibilidade do investimento em relação ao fluxo de caixa ocorreu para a região Nordeste. As firmas dessa região podem ser consideradas como restritas financeiramente, já que não estão sujeitas à crítica de que o fluxo de caixa estaria indicando um potencial de rentabilidade futura. Isto é corroborado quando se observa um reduzido e negativo valor para a lucratividade das firmas dessa região. Outro indicador que aponta claramente para o importante papel do fluxo de caixa para explicar o comportamento do investimento é a elevada necessidade de caixa apresentada pelas firmas da região Nordeste, apresentando reduzidos valores para as variáveis que indicam folga de caixa.

De acordo com os resultados, observou-se que a região Nordeste apresenta a maior sensibilidade do investimento ao fluxo de caixa, indicando que as firmas pertencentes às regiões menos abastadas e com um sistema financeiro menos desenvolvido apresentam maiores restrições de financiamento e dependem mais fortemente de recurso internos. Este resultado preliminar sugere que a análise das diferenças regionais na importância do investimento são fatores que devem ser estudados mais detalhadamente. Esta é uma importante informação para a elaboração de políticas regionais, uma vez que política de crédito de longo prazo sem considerar diferenças regionais pode conduzir a uma situação em que os resultados não sejam ótimos.

Referências Bibliográficas

Azzoni, C. R.; Servo, L. M. Education, cost of living and regional wage inequality in Brazil in the 90s. *Papers in Regional Science*, vol. 81, p. 157-175, 2002.

Beck, T.; Levine, R. e. Loayza, N. Finance and the sources of growth. *Journal of Financial Economics*, vol. 58, p. 261-300, 2000.

Booth, L.; Cleary, S. Cash Flow Volatility, Financial Slack and Investment Decisions, 2006.

Campelo, M.; Weisbach, M. S. The Cash Flow Sensivity of Cash. *The Journal of Finance*, vol.59, n.4, p.1777-1804, 2004.

Fazzari, S. M.; Hubbard, G.; Petersen, B. Financing constraints and corporate investment. *Brookings Papers on Economic Activity*, n.1, p.141-95, 1988.

Gamerman, D.; Migon, S. H. Inferência Estatística: Uma abordagem Integrada. Rio de Janeiro, 1997.

Gelfand, A.; Dey, K. D. Bayesian Model Choice: Asymptotics and Exacts Calculations. *Journal of the Royal Statistician Society, Series B*, vol.56, n.3, p. 501-514. 1994.

Gelman, A.; Rubin, D. Inference form Iterative Simulation Using Multiple Sequence. *Statistical Science*, vol.7, n.4, p.457-472, 1992.

Hafer, R.W and Jansen, W. D. The Demand for Money in the United States: Evidence from Cointegration Tests. *Journal of Money, Credit & Banking*, Vol. 23, 1991.

Hastings, W. K. Monte Carlo Sampling Methods Using Markov Chains and Their Applications, *Biometrika*, vol.57, p. 97-109, 1970.

Hsiao, C.; Pesaran, H.; Tahmiscioglu, A. K. A. A Bayes Estimation of Short-Run Coefficients in Dynamic Panel Data. Revised version of paper presented in Seventh International Conference on Panel Data, Paris, June, 1997.

Hsiao, C.; Tahmiscioglu, A. K. A Panel Analysis of Liquidity Constraints and Firm Investment. *Journal of the Statistical Association*, vol.92, n.438, p.455-465, 1997.

Jensen, M. Agency Costs of Free Cash Flow, Corporate Finance, and Takeovers. *The American Economic Review*, vol. 76, p. 323-329, 1986.

Kaplan, S.; Zingales, L. Investment – cash flow sensitivities are not valid measures of financing constraints. *NBER, Working Paper*, n.7659, USA, 2000.

Kass, R. Bayes Factor in Praticce. *The Statistician*, vol. 42, n. 5, p. 551-560, 1992.

Kass, R.; Raftery, E. A. Bayes Factor. *Journal of the American Statistical Association*, vol. 90, n. 340, p. 773-795, 1995.

King, R. G.; Levine, R. Finance and growth: Schumpeter might be right. *Quarterly Journal of Economics*, vol. 108, n. 3, p. 717-737, 1993.

Koop, G. Bayesian Econometrics. Wiley, 2003.

Khurana, I.; Pereira, R.; Martin, X. Financial Development and the Cash Flow Sensitivity of Cash. *Journal of financial and Quantitative Analysis*, forthcoming 2006.

Lancaster, T. An Introduction to Modern Bayesian Econometrics. Blackwell, 2004.

Levine, R. Financial Development and Economic Growth: Views and Agenda. *Journal of Economic Literature*, v. 25, p. 688-726, 1997.

Beck, T. Levine, R. Loayza, N. Finance and the sources of growth. *Journal of Financial Economics*, vol 58, p. 261-300, 2000.

Metropolis, N.; Rosenbluth, A.E.; Rosenbluth, M.N.; Teller, A.E.; Teller, E. Equation of State Calculations by Fast Computing Machines. *Journal of Chemical Physics*, 1953, vol.21, p.1087-1092.

Rajan, R.; Zingales, L. Financial dependence and growth. *The American Economic Review*, 1998, vol. 88, p. 559-586.

Spiegelhalter, D.J.; Thomas, A.; Best, N.G.; Gilks, W.R. Winbugs: Bayesian Inference using Gibbs Sampling. MRC. Biostatistics Unit, Cambridge. 1995.

Stiglitz, J.; Weiss, A. Credit rationing in markets with imperfect information. *American Economic Review*, 1981, vol.71, n.3, p.393-410.

Stiglitz, J. Peer Monitoring and Credit Markets. *The World Bank Economic Review*, 1990, vol. 4, n. 3, p. 351-366.

Weakliem, L. D. A Critique of the Bayesian Information Criterion for Model Selection. *Sociological Methods & Research*, Vol. 27, No. 3, 359-397, 1999.

APÊNDICE A

Para obter a função de verossimilhança e as densidades condicionais a posteriori para os parâmetros do modelo, considere a seguinte expressão:

$$e_{it} = y_{it} - a_i - w_t - \sum_{l=1}^5 b_l x_{lit}$$

Além disso, adotou-se a notação $\Theta_{(q_l)}$ para indicar um vetor de parâmetros de dimensão L,, dado por $\Theta = (q_1, q_2, \dots, q_{l-1}, q_{l+1}, \dots, q_L)$, em que q_l não está presente.

A densidade conjunta a priori, a função de verossimilhança e as densidades condicionais a posteriori para os parâmetros do modelo assumindo uma distribuição normal e uma *t* de *student* são apresentadas abaixo:

(A.1) - Modelo com uma normal

(A.1.1) - Efeito Fixo

Densidade conjunta a priori:

$$p\left(\underset{\sim}{a}, \underset{\sim}{b}, \underset{\sim}{w}, s^2\right) \propto \frac{1}{f_1 - e_1} \cdot \frac{1}{f_2 - e_2} \cdot \exp\left\{-\frac{1}{2} \sum_{l=1}^5 \frac{1}{b_{lj}^2} (b_{lj} - a_{lj})^2\right\} \cdot (s^2)^{-(c+1)} \exp\left\{-\frac{d}{s^2}\right\}$$

Função de Verossimilhança:

$$L(\underset{\sim}{q}) = \prod_{i=1}^N \prod_{t=1}^T f(e_{it}/m, s^2) = (s^2)^{-\frac{NT}{2}} \exp\left[-\frac{1}{2s^2} \sum_{i=1}^N \sum_{t=1}^T (e_{it})^2\right], \quad \underset{\sim}{q} = \left(\underset{\sim}{a}, \underset{\sim}{b}, \underset{\sim}{w}, s^2\right)$$

Densidade condicional a posteriori para $\underset{\sim}{a}$:

$$\underset{\sim}{a} / \underset{\sim}{q}_{(\underset{\sim}{a})}, \underset{\sim}{y}, \underset{\sim}{x} \sim N\left(\frac{\sum_{t=1}^T \left(y_{it} - w_t - \sum_{l=1}^5 b_{lj} x_{lit}\right)}{T}; \frac{s^2}{T}\right)$$

Densidade condicional a posteriori para $\underset{\sim}{w}$:

$$\underset{\sim}{w} / \underset{\sim}{q}_{(\underset{\sim}{w})}, \underset{\sim}{y}, \underset{\sim}{x} \sim N\left(\frac{\sum_{i=1}^N \left(y_{it} - a_i - \sum_{l=1}^5 b_{lj} x_{lit}\right)}{N}; \frac{s^2}{N}\right)$$

Densidade condicional a posteriori para b_{lj} :

$$b_{lj}/q_{\sim(b_{lj})}, y, x \sim N \left(\frac{a_{lj} s^2 + b_{lj}^2 \sum_{i=1}^N \sum_{t=1}^T x_{lit} \left(y_{it} - a_i - w_t - \sum_{k=1, k \neq l}^5 b_{kj} x_{lit} \right)}{s^2 + b_{lj}^2 \sum_{i=1}^N \sum_{t=1}^T (x_{lit})^2}, \frac{b_{lj}^2 s^2}{s^2 + b_{lj}^2 \sum_{i=1}^N \sum_{t=1}^T (x_{lit})^2} \right)$$

Densidade condicional a posteriori para s^2 :

$$s^2/q_{\sim(s^2)}, y, x \sim IG \left(c + \frac{NT}{2}; d + \frac{1}{2} \sum_{i=1}^N \sum_{t=1}^T \left(y_{it} - a_i - w_t - \sum_{l=1}^5 b_{lj} x_{lit} \right)^2 \right)$$

(A.1.2) - Efeito Aleatório

Densidade conjunta a priori:

$$p \left(a_{\sim}, b_{\sim}, w_{\sim}, s_a^2, s_w^2, s_w^2 \right) \propto (s_a^2)^{-\frac{N}{2}} \exp \left\{ -\frac{1}{2s_a^2} \sum_{i=1}^N a_i^2 \right\} \cdot (s_w^2)^{-\frac{T}{2}} \exp \left\{ -\frac{1}{2s_w^2} \sum_{t=1}^T w_t^2 \right\} \cdot \exp \left\{ -\frac{1}{2} \sum_{l=1}^5 \frac{1}{b_{lj}^2} (b_{lj} - a_{lj})^2 \right\} \cdot (s^2)^{-(c_1+1)} \exp \left\{ -\frac{d_1}{s^2} \right\} \cdot (s_a^2)^{-(c_2+1)} \exp \left\{ -\frac{d_2}{s_a^2} \right\} \cdot (s_w^2)^{-(c_2+1)} \exp \left\{ -\frac{d_2}{s_w^2} \right\}$$

Função de Verossimilhança:

$$L(q) = \prod_{i=1}^N \prod_{t=1}^T f(e_{it}/m, s^2) = (s^2)^{-\frac{NT}{2}} \exp \left[-\frac{1}{2s^2} \sum_{i=1}^N \sum_{t=1}^T (e_{it})^2 \right], \quad q = \left(a_{\sim}, b_{\sim}, w_{\sim}, s^2, s_a^2, s_w^2 \right)$$

Densidade condicional a posteriori para a :

$$a_{\sim}/q_{\sim(a_{\sim})}, y, x \sim N \left(\frac{s_a^2 \sum_{t=1}^T \left(y_{it} - w_t - \sum_{l=1}^5 b_{lj} x_{lit} \right)}{s^2 + T s_a^2}, \frac{s_a^2 s^2}{s^2 + T s_a^2} \right)$$

Densidade condicional a posteriori para w :

$$w_{\sim}/q_{\sim(w_{\sim})}, y, x \sim N \left(\frac{s_w^2 \sum_{i=1}^N \left(y_{it} - a_i - \sum_{l=1}^5 b_{lj} x_{lit} \right)}{s^2 + N s_w^2}, \frac{s_w^2 s^2}{s^2 + N s_w^2} \right)$$

Densidade condicional a posteriori para b_{lj} :

$$b_{lj}/q_{(b_{lj})}, y, x \sim N \left(\frac{a_{lj} s^2 + b_{lj}^2 \sum_{i=1}^N \sum_{t=1}^T x_{lit} \left(y_{it} - a_i - w_t - \sum_{k=1, k \neq l}^5 b_{kj} x_{kit} \right)}{s^2 + b_{lj}^2 \sum_{i=1}^N \sum_{t=1}^T (x_{lit})^2}, \frac{b_{lj}^2 s^2}{s^2 + b_{lj}^2 \sum_{i=1}^N \sum_{t=1}^T (x_{lit})^2} \right)$$

Densidade condicional a posteriori para s^2 :

$$s^2/q_{(s^2)}, y, x \sim IG \left(c_1 + \frac{NT}{2}; d_1 + \frac{1}{2} \sum_{i=1}^N \sum_{t=1}^T \left(y_{it} - a_i - w_t - \sum_{l=1}^5 b_{lj} x_{lit} \right)^2 \right)$$

Densidade condicional a posteriori para s_a^2 :

$$s_a^2/q_{(s_a^2)}, y, x \sim IG \left(c_2 + \frac{N}{2}; d_2 + \frac{1}{2} \sum_{i=1}^N a_i^2 \right)$$

Densidade condicional a posteriori para s_w^2 :

$$s_w^2/q_{(s_w^2)}, y, x \sim IG \left(c_3 + \frac{T}{2}; d_3 + \frac{1}{2} \sum_{t=1}^T w_t^2 \right)$$

(A.2) - Modelo com uma t de student

(A.2.1) - Efeito Fixo

A densidade conjunta a priori para o modelo de efeito fixo que assume uma distribuição t de *student* para o erro é análoga à densidade conjunta a priori para o modelo que considera uma normal para o erro.

Função de verossimilhança:

$$L(q) = \prod_{i=1}^N \prod_{t=1}^T \frac{1}{\sqrt{p s k}} \left[1 + \frac{(e_{it})^2}{k s^2} \right]^{-\left(\frac{k+1}{2}\right)}, \quad q = (a, b, w, s^2)$$

Densidade condicional a posteriori para a :

$$p \left(a/q_{(a)}, y, x \right) \propto \prod_{i=1}^N \prod_{t=1}^T \left[1 + \frac{(a_i - l_{it}^{(1)})^2}{k s^2} \right]^{-\frac{k+1}{2}}, \quad l_{it}^{(1)} = y_{it} - w_t - \sum_{l=1}^5 b_{lj} x_{lit}$$

Densidade condicional a posteriori para w :

$$p\left(\frac{w}{q_{(w)}}, y, x\right) \propto \prod_{i=1}^N \prod_{t=1}^T \left[1 + \frac{(w_t - l_{it}^{(2)})^2}{ks^2}\right]^{-\frac{k+1}{2}}, \quad l_{it}^{(2)} = y_{it} - a_i - \sum_{l=1}^5 b_{lj} x_{lit}$$

Densidade condicional a posteriori para b_{lj} :

$$p\left(\frac{b_{lj}}{q_{(b_{lj})}}, y, x\right) \propto \exp\left[-\frac{1}{2b_{lj}^2}(b_{lj} - a_{lj})^2\right] \cdot \prod_{i=1}^N \prod_{t=1}^T \frac{1}{\sqrt{psk}} \cdot \left(1 + \frac{e_{it}^2}{ks^2}\right)^{-\left(\frac{k+1}{2}\right)}$$

Densidade condicional a posteriori para s^2 :

$$p\left(\frac{s^2}{q_{(s^2)}}, y, x\right) \propto (s^2)^{-(c+1)} \cdot \exp\left(-\frac{d}{s^2}\right) \cdot \prod_{i=1}^N \prod_{t=1}^T \frac{1}{\sqrt{psk}} \cdot \left(1 + \frac{(e_{it})^2}{ks^2}\right)^{-\left(\frac{k+1}{2}\right)}$$

(A.2.2) - Efeito Aleatório

A densidade conjunta a priori para o modelo de efeito aleatório que assume uma distribuição t de *student* para o erro é análoga à densidade conjunta a priori para o modelo que considera uma normal para o erro. O mesmo acontece para as densidades condicionais a posteriori dos hiperparâmetros s_a^2 e s_w^2 .

Função de Verossimilhança:

$$L(q) = \prod_{i=1}^N \prod_{t=1}^T \frac{1}{\sqrt{psk}} \left[1 + \frac{(e_{it})^2}{ks^2}\right]^{-\left(\frac{k+1}{2}\right)}, \quad q = \left(\frac{a}{q_{(a)}}, \frac{b}{q_{(b)}}, \frac{w}{q_{(w)}}, s^2, s_a^2, s_w^2\right)$$

Densidade condicional a posteriori para a :

$$p\left(\frac{a}{q_{(a)}}, y, x\right) \propto \exp\left(-\frac{1}{2s_a^2} \sum_{i=1}^N a_i^2\right) \cdot \prod_{i=1}^N \prod_{t=1}^T \left[1 + \frac{(a_i - l_{it}^{(1)})^2}{ks^2}\right]^{-\frac{k+1}{2}}, \quad l_{it}^{(1)} = y_{it} - w_t - \sum_{l=1}^5 b_{lj} x_{lit}$$

Densidade condicional a posteriori para w :

$$p\left(\frac{w}{q_{(w)}}, y, x\right) \propto \exp\left(-\frac{1}{2s_w^2} \sum_{t=1}^T w_t^2\right) \cdot \prod_{i=1}^N \prod_{t=1}^T \left[1 + \frac{(w_t - l_{it}^{(2)})^2}{ks^2}\right]^{-\frac{k+1}{2}}, \quad l_{it}^{(2)} = y_{it} - a_i - \sum_{l=1}^5 b_{lj} x_{lit}$$

As densidades condicionais a posteriori para b_{lj} e s^2 são análogas àquelas encontradas considerando um modelo de efeito fixo.