

TRANSPARÊNCIA E IMAGEM DO BANCO CENTRAL DO BRASIL: UMA COMPARAÇÃO ENTRE TÉCNICAS DE ANÁLISE

Paulo Roberto da Costa Vieira*
José Roberto Ribas**

Resumo: O presente artigo avalia as vantagens comparativas da Regressão Logística e da Modelagem de Equações Estruturais para estimar o impacto da transparência na imagem institucional do Banco Central do Brasil, estimulando a discussão acerca da escolha da técnica analítica mais adequada ao tratamento da intrincada relação entre variáveis relacionadas ao regime de metas inflacionárias. A coleta de dados foi realizada por intermédio de questionário estruturado e auto-administrado, cujas questões não-dicotômicas foram medidas com escala Likert de cinco alternativas. Embora a modelagem de equações estruturais seja capaz de produzir o maior volume de insights, os resultados mostram que a regressão logística é recomendada quando há significativa restrição orçamentária.

Palavras-chave: Transparência. Imagem institucional. Meta inflacionária. Banco Central.

Abstract: This paper evaluates the comparative advantages of Logistic Regression and Structural Equation Modeling to estimate the impact of transparency on institutional image of the Central Bank of Brazil. The purpose is to stimulate the discussion on which choice of analytical technique should be more appropriate to (deal with?) process the complex relationship among variables related to inflation targeting. Data collection was performed by structured questionnaire and self-administered, whose non-dichotomous questions were measured by Likert scale of five alternatives. Although the structural equation modeling is able to produce the biggest volume of insights, the outcomes depict that the logistic regression is most recommended when there is a substantial budgetary restriction.

Keywords: Transparency, Institutional image, Inflation targeting, Central Bank.

JEL classification: E52, Monetary policy; E58, Central Banks and their policies; E59, Other.

* Banco Central do Brasil e Universidade Estácio de Sá. E-mail: paulorcvc@bcb.gov.br

** Doutor em Administração de Empresas pela EAESP/FGV. Professor Adjunto de Mestrado em Administração e Desenvolvimento Empresarial da Universidade Estácio de Sá. E-mail: jose.ribas@estacio.br

1 Introdução

Num mundo regido pela escassez de recursos, a escolha entre alternativas possíveis constitui questão essencial. O avanço científico exige a contínua realização de pesquisa, não obstante o implacável princípio da limitação de recursos. A busca pela otimização de resultados, com dotação orçamentária invariavelmente aquém das necessidades do estudo, acompanha o pesquisador qual sombra. A situação se torna mais dramática para o pesquisador de ciências sociais que trabalha sistematicamente com dados primários, realizando pesquisa de *survey*.

Nesse contexto, emerge, entre tantas questões relevantes, aquela referente à seleção da técnica estatística mais adequada ao tratamento dos dados, já que o benefício marginal representado pelo conhecimento mais profundo do fenômeno estudado necessita superar o custo marginal representado pelos recursos alocados na coleta de dados, a qual deve estar moldada não somente à finalidade da pesquisa, como também às exigências estabelecidas pela ferramenta estatística selecionada.

O presente estudo realiza avaliação empírica dos benefícios comparativos entre a Regressão Logística (RL) e a Modelagem de Equações Estruturais (MEE) que constituem duas poderosas ferramentas estatísticas de natureza *multivariada* à disposição dos pesquisadores da área de negócios. Para atingir seu objetivo precípuo de análise comparativa entre as ferramentas estatísticas acima citadas, realizou-se pesquisa de *survey* com especialistas do mercado financeiro, objetivando avaliar a influência da transparência sobre a imagem do Banco Central do Brasil.

Além da presente introdução, o artigo está estruturado em outras quatro seções. Na seção seguinte, apresenta-se o referencial teórico do estudo, no qual está englobada a discussão das características essenciais da regressão logística e da modelagem de equações estruturais, bem como a exposição da atuação que a moderna literatura macroeconômica espera dos bancos centrais, inserindo nesse contexto o impacto que a transparência exerce so-

bre a imagem institucional da Autoridade Monetária. A terceira seção detalha o procedimento metodológico adotado na pesquisa. A quarta seção interpreta os resultados do estudo, cabendo à última seção discutir as suas conclusões.

2 Referencial Teórico

2.1 Regressão Logística: características essenciais

A Regressão Logística (RL) é empregada quando as variáveis independentes são utilizadas na explicação de resultado categórico. A RL é especialmente indicada para os casos em que a variável dependente assume apenas dois valores, malgrado possa ser naturalmente estendida a situações que envolvam variável com três ou mais categorias (variável dependente *multinomial*). A questão relevante é verificar, se a variável dependente for dicotômica, como os casos são classificados em uma dentre as duas categorias, assumindo o valor 1, com probabilidade de sucesso p ; ou o valor 0, com probabilidade de insucesso $1 - p$.

Se a probabilidade de $Y=1$ fosse modelada como $p = \alpha + \beta X$, embora a probabilidade dos valores observados de Y estarem efetivamente entre 0 e 1, os valores preditos poderiam apresentar probabilidades menores que zero ou superiores a 1. Para resolver essa inconsistência, é imprescindível se substitua a probabilidade de $Y=1$ pela chance de $Y=1$. A chance ($Y=1$) é a razão entre a probabilidade de $Y=1$ e a probabilidade de $Y=1$, ou seja, $p/[1 - p]$. Ao contrário de p , a chance não tem valor máximo fixo, nada obstante, tal como a probabilidade, tenha valor mínimo 0.

Enquanto o coeficiente de regressão linear tem interpretação imediata, uma vez que estima a variação na variável dependente para qualquer unidade de incremento na variável independente, a interpretação dos coeficientes de RL exige a compreensão do conceito de chance (Liao, 1994).

Caso exista probabilidade de que algum evento ocorra ou caso seja constatada a presença de

determinado atributo, então, a chance é, em média, o número de sucessos que se espera venha acontecer pelo número de insucessos. Chances elevadas correspondem a altas probabilidades, ao passo que chances reduzidas estão relacionadas a probabilidades diminutas. Pode-se facilmente converter chance em probabilidade. Imagine que a variável dependente da investigação seja dicotômica, tal como prestígio da Diretoria do Banco Central, que, quando codificada com 1, representa “ter prestígio”; e 0 significa “não ter prestígio”.

Define-se chance (c) como sendo igual a:

$$c = p/(1 - p) \quad (1)$$

onde: c é a chance; p é a probabilidade do evento codificado com 1 (*ter prestígio*); e $(1 - p)$ é probabilidade do evento codificado com 0 (*não ter prestígio*).

A probabilidade do evento codificado como 1 pode ser encontrada em função da chance da seguinte forma:

$$c = p/(1 - p) \quad (2)$$

$$p = c/(1 + c) \quad (3)$$

Logo, tem-se que:

$$\text{Probabilidade} = \text{chance}/(1 + \text{chance}) \quad (4)$$

O modelo de RL prevê o logaritmo natural da chance, também conhecido como *logit*, pois a forma *logit* de probabilidade possibilita melhor análise da variável dependente dicotômica. O *logit* torna-se negativo e crescentemente maior em valor absoluto quando a chance decresce de 1 em direção a 0, tornando-se crescentemente maior na direção positiva quando a chance aumenta de 1 ao infinito (Liao, 1994).

A RL não presume linearidade da relação entre as variáveis independentes e a dependente; não requer variáveis normalmente distribuídas; e não supõe homoscedasticidade. Contudo, ela exige que as observações sejam independentes e que as variáveis independentes estejam linearmente relacionadas ao *logit* da variável dependente. A equação da relação entre a variável dependente e a independente é:

$$\text{logit}(Y) = \ln(\text{chance}) = \ln[p/(1-p)] = \alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k \quad (5)$$

Cabe notar, que X_i são variáveis independentes, onde $i = 1, \dots, k$.

Podemos converter *logit* (Y) para chance, por meio da função exponencial:

$$[\text{chance de } Y=1] = e^{\text{logit}(Y)} \quad (6)$$

$$[\text{chance de } Y=1] = e^{(\alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k)} \quad (7)$$

Nesse caso, a variação de uma unidade em X multiplica a chance de e^β . Então, pode-se converter chance na probabilidade de que $Y=1$, por meio da fórmula:

$$P(Y=1) = [\text{chance que } Y=1]/[1 + \text{chance que } Y=1]. \quad (8)$$

Isso gera:

$$P(Y=1) = [e^{(\alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k)}]/[1 + e^{(\alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k)}] \quad (9)$$

O cálculo de probabilidade pela fórmula acima, garante que ela nunca será menor que 0 ou maior do que 1. Para estimar os parâmetros, emprega-se a técnica de máxima verossimilhança, com repetição do processo até que a mudança na função verossimilhança de um passo do processo ao subsequente seja desprezível (Menard, 2002).

2.2 Equações Estruturais: aspectos fundamentais

A Modelagem de Equações Estruturais (MEE) é uma família de técnicas estatísticas que inclui e integra a análise de caminho e a análise fatorial, estimando, simultaneamente, uma série de equações de regressão que, embora separadas, são interdependentes. No caso em que cada variável tenha apenas um indicador, a MEE se restringe à análise de caminho. Quando cada variável apresenta múltiplos indicadores, mas inexistem efeitos diretos que as conectem, tem-se a análise fatorial. Entretanto, quando há indicadores múltiplos para cada variável latente (ou fator), bem como caminhos que as conectem, são construídos modelos híbridos. As relações entre variáveis são definidas, em MEE, por um conjunto de equações que descrevem estruturas hipotéticas de relacionamento. A MEE é uma metodologia estatística empregada principalmente

por pesquisadores de ciências sociais, pois constitui método de grande alcance no tocante à quantificação e ao teste de teorias (Raykov; Marcoulides, 2000).

Não há método operacional que possibilite a mensuração direta de variáveis latentes (ou construtos hipotéticos), embora possam ser mensuradas por intermédio das variáveis observadas representativas de suas múltiplas facetas ou características essenciais. Com base nas variáveis observadas, a MEE não apenas estima os construtos, mas testa a qualidade de ajustamento global do modelo, bem como a consistência de seus parâmetros. Ademais, os modelos estruturais consideram o erro de mensuração em variáveis observadas, sejam variáveis independentes, sejam dependentes, possibilitando estimativas explícitas dos parâmetros da variância dos erros. Métodos alternativos, como modelos de regressão linear, supõem que os erros das variáveis independentes tendem a zero. Ignorar os referidos erros pode levar a sérias distorções, especialmente quando são significativos. Os modelos estruturais contemplam também efeitos diretos e indiretos das distintas variáveis que dele participam (Raykov; Marcoulides, 2000).

Em geral, o MEE é comunicado por meio de desenho, denominado diagrama de caminho (*path diagram*). O diagrama de caminho utiliza uma notação gráfica especial, consistindo de retângulos (ou quadrados) e elipses (ou círculos), conectados por flechas que indicam causalidade, quando retas; ou covariância, quando curvas. As variáveis dependentes recebem pelo menos um caminho (flecha de sentido único) de outra variável no modelo, enquanto as independentes originam caminhos, cabendo notar que uma dependente pode agir como independente, sem que a sua condição de dependente seja modificada.

Avaliar o grau em que um modelo hipotético se ajusta ou, em outras palavras, descreve adequadamente os dados da amostra, constitui objetivo fundamental em MEE. Em termos mais específicos, a avaliação deveria destacar a adequação: a) do modelo como um todo; e b) das estimativas dos parâmetros.

A MEE não utiliza, no processo de estimação, os dados diretamente coletados, mas sim a matriz de covariância produzida a partir dos referidos dados. Com base no modelo construído de equações estruturais, é produzida uma matriz de covariância, Σ , denominada matriz de covariância reproduzida, com $\{[p(p + 1)]/2\}$ elementos não redundantes, sendo p o número de variáveis observadas. Os elementos de Σ são todos funções dos parâmetros do modelo. Cada elemento da matriz Σ tem um elemento numérico correspondente na matriz de covariância observada, S , obtida a partir dos valores da amostra para as variáveis V_i ($i = 1 \dots p$).

O modelo se ajusta aos dados observados na mesma extensão da equivalência existente entre a matriz de covariância gerada pelo modelo, Σ , e a matriz de covariância observada, S . Em ajustamento de excelência, a matriz de resíduos tende a zero. O objetivo final do pesquisador é determinar o modelo que gerou a matriz de covariância da amostra. A questão fundamental é, dessa maneira, inquirir em que medida o modelo verdadeiro se desvia do testado.

A relação entre a matriz de covariância original e a reproduzida pode ser testada por significância, calculando-se a estatística *qui-quadrado* (χ^2). Um valor χ^2 elevado, relacionado a um determinado nível de significância (α), indica que o modelo não se ajusta aos dados. Se o valor χ^2 for zero, então, a correlação original e a reproduzida na matriz são idênticas. Em outras palavras, as covariâncias são perfeitamente reproduzidas pelo modelo estrutural. Há um problema sério com a estatística χ^2 como índice de ajustamento, pois é muito sensível ao tamanho da amostra. Ou seja, quando o tamanho da amostra é grande, o que constitui uma condição necessária para que o índice possa ser interpretado como teste de significância, então, a estatística χ^2 pode ser significativa, ainda que a diferença entre as covariâncias observadas e as originadas pelo modelo sejam desprezíveis. Quando o tamanho da amostra decresce (geralmente abaixo de 100), o teste χ^2 indica níveis de probabilidade não significativos.

Em decorrência dos problemas apontados anteriormente para o teste χ^2 , os pesquisadores di-

videm o valor χ^2 pelos graus de liberdade (g.l), para reduzir o seu valor, bem como a sensibilidade da estatística χ^2 ao tamanho da amostra. No AMOS 4.0, a razão χ^2 /graus de liberdade aparece como CMIN/DF, a qual mostra a diferença entre as matrizes de covariância observada e estimada. Embora não haja uma regra que aponte o valor mínimo aceitável para χ^2/df , uma sugestão freqüente é que essa razão seja menor do que 3. O *qui-quadrado* (χ^2) é o único teste de significância estatística da modelagem de equações estruturais, muito embora sejam calculados diversos índices de bondade de ajustamento (Kline, 2005).

Os índices de ajustamento poderiam ser classificados em incremental e absoluto. Entre os índices de ajustamento absoluto, cabe menção ao GFI (*Goodness of Fit Index*) e ao AGFI (*Adjusted Goodness of Fit Index*), pois são os mais amplamente utilizados.

O índice de bondade do ajustamento GFI (*Goodness of Fit Index*) é medida não estatística do grau de adequação do modelo, variando de 0 (ajustamento pobre) até 1,0 (ajustamento perfeito), embora possa assumir, teoricamente, valores negativos. O GFI é análogo ao R^2 , tendo em vista que indica a proporção das covariâncias observadas que é explicada pelas covariâncias originadas pelo modelo. Magnitudes mais elevadas de GFI indicam melhores ajustamentos, sendo sugerido um nível absoluto mínimo de 0,90 para que o modelo seja aceito (Byrne, 2001).

O índice de bondade do ajustamento ajustado (*Adjusted Goodness of Fit Index-AGFI*) é uma variante do GFI, ajustando-o aos graus de liberdade do modelo em relação ao número de variáveis. Ele também varia de 0 a 1. O AGFI é análogo ao R^2 ajustado. Especificamente, modelos mais complexos, ou seja, aqueles com mais parâmetros, tendem a se ajustar melhor aos mesmos dados do que os mais simples. O AGFI leva isso em consideração, corrigindo para baixo o valor do GFI quando o número de parâmetros aumenta. O nível de aceitação sugerido é um valor superior ou igual a 0,90 (Byrne, 2001).

Na categoria de índice incremental, a raiz do erro de aproximação quadrático médio (RMSEA) constitui representante de excelência. O conjunto

de estatísticas de ajustamento concentrado na raiz do erro de aproximação quadrático médio (RMSEA) é considerado um critério muito informativo da modelagem da estrutura de covariância, avaliando quão bem o modelo se ajustaria à matriz de covariância da população, caso estivesse disponível. Os índices cujos valores sejam inferiores a 0,05 indicam um bom ajustamento. Valores maiores de 0,05 e inferiores a 0,08 representam ajustamento razoável. Valores variando de 0,08 a 0,10 indicam ajustamentos pobres (Arbuckle; Wothke, 1999).

No tocante à viabilidade dos parâmetros estimados, deve-se verificar se apresentam a magnitude e o sinal consistentes com os pressupostos teóricos. É preciso verificar também a presença, ou não, de erros padrões exageradamente elevados ou diminutos. A significância estatística da estimativa do parâmetro é determinada, no programa AMOS 4.0, pela razão crítica (C.R). O teste estatístico C.R representa a estimativa do parâmetro dividido por seu erro padrão. O teste opera como uma estatística z, testando se a estimativa é estatisticamente diferente de zero. Quando se considera um nível de significância de 0,05, as estimativas, com razões críticas superiores ao valor absoluto de $\pm 1,96$, são significativamente diferentes de zero no nível de 5%.

Convém notar que parâmetros não significativos podem indicar um tamanho de amostra que seja demasiadamente pequeno. Em MEE há diversos fatores que restringem o tamanho da amostra, sendo, todavia, 100 observações o tamanho mínimo aceitável (Hair *et al.*, 2005).

Hu e Bentler (1995) realizaram estudos baseados em simulação de Monte Carlo, cujos resultados revelaram que o tamanho da amostra deve preferencialmente superar 250 observações, para que índices de bondade de ajustamento relacionados a modelos híbridos, notadamente os da categoria incremental, reflitam a qualidade do ajustamento.

À medida que o tamanho da amostra diminui e a distribuição das variáveis se distancia da normal, cresce, na MEE, a probabilidade de não ocorrência de convergência do modelo ou de geração de resultados incorretos (Byrne, 2001).

2.3 Transparência e imagem do Banco Central do Brasil

Para que a importância da transparência possa ser, sob a perspectiva da literatura macroeconômica, mais facilmente avaliada, é imprescindível que os fundamentos do principal paradigma macroeconômico atual sejam conhecidos.

Após a II Guerra Mundial, os formuladores da política econômica dispunham de modelos macroeconômicos keynesianos, que prescreviam as medidas a serem adotadas para atingir um nível desejado de emprego e de produto. Sob a perspectiva teórica da Curva de Phillips, haveria um *trade-off* entre a taxa de desemprego e a inflação. Se o governo adotasse uma política fiscal expansionista – quer aumentando gastos quer reduzindo impostos, ou, ainda, mediante uma combinação de ambos – o resultado seria uma queda da taxa de desemprego, muito embora acompanhada de elevação da taxa de inflação. Caso optasse por uma política monetária de redução da taxa de juros, haveria crescimento do investimento, ocorrendo a conseqüente redução da taxa de desemprego. O aumento da oferta monetária, que teria ocasionado a redução da taxa de juros, produziria, por seu turno, elevação da taxa de inflação.

Todavia, em uma época com taxas de inflação residuais e uma preocupação crescente com aumento do nível de emprego, o *trade-off* da Curva de Phillips não preocupava. Entretanto, a aplicação de modelos fundamentados na Curva de Phillips produziu, notadamente na década de 1970, resultados imprevistos e adversos, pois gerou tanto a aceleração da inflação, como a elevação da taxa de desemprego (Friedman, 1985).

No início da década de 1970, surgiu, no meio acadêmico, um novo modelo, conhecido como macroeconomia novo-clássica, cuja hipótese fundamental de expectativas racionais por parte dos agentes econômicos iria influenciar profundamente a literatura econômica. Se considerarmos as hipóteses de competição perfeita e de expectativas racionais, poderemos trabalhar com um modelo macroeconômico

que estabelece um jogo entre o governo e o setor privado. Nesse jogo, cada lado tenta se antecipar às ações do outro, buscando sempre resultados ótimos. A existência de expectativas racionais pressupõe que os agentes econômicos não apenas utilizam, da melhor forma possível, todas as informações disponíveis, mas também as processam por intermédio de um paradigma de funcionamento da economia, que é por todos partilhado. Tal paradigma é empregado para formar ou atualizar as expectativas (Cysne; Simonsen, 1995).

No ambiente das expectativas racionais, não existiria o *trade-off* entre taxa de inflação e taxa de desemprego postulado pela Curva de Phillips, eliminando-se, assim, o espaço de manobra para as políticas de gerenciamento da demanda, uma vez que a elevação de preços é imediatamente antecipada pelos agentes econômicos. Em outras palavras, as referidas políticas só poderiam ser efetivas se os agentes econômicos incorressem em erros sistemáticos de previsão, o que conflitaria frontalmente com a existência de expectativas racionais.

Sendo assim, caberia ao Banco Central, no contexto de expectativas racionais, eleger como meta uma variável nominal para monitoramento, como a taxa de inflação no regime de metas inflacionárias, já que não teria como alterar a longo termo as variáveis reais da economia.

Embora a Autoridade Monetária possa desejar que todos tenham expectativas de inflação reduzida, o anúncio de compromisso com uma inflação baixa não o torna, por si só, crível. Isso ocorre porque os agentes econômicos têm plena consciência de que o Banco Central pode se sentir estimulado a descumprir o anunciado, caso vise reduzir a taxa de desemprego. É nesse cenário que se discute o papel do Banco Central, a sua forma de atuação, os seus compromissos fundamentais, entre os quais a transparência, bem como o significado e a construção de sua imagem (Blinder, 1996; 1999a; 1999b).

A conjectura de que a Autoridade Monetária poderia deixar de honrar o anunciado produziria uma revisão adversa nas expectativas dos agentes eco-

nômicos, justificando, dessa forma, o estabelecimento formal de uma regra de política monetária. Atualmente, essa regra está consubstanciada, para um expressivo número de países, no regime de metas inflacionárias (Mendonça, 2006).

O governo delegaria a formulação e a condução da política monetária ao Banco Central autônomo, cuja missão seria manter, segundo uma regra preestabelecida, a estabilidade de preços, perseguindo apenas uma meta inflacionária verossímil que deveria ser antecipadamente anunciada. A percepção que o público possui do Banco Central depende da confiança que se deposita na capacidade de a instituição manter os preços estáveis. Essa confiança deve ser conquistada, preservada e confirmada por meio de ações desenvolvidas ao longo do tempo. Quanto mais bem-sucedido no cumprimento do papel de guardião da estabilidade da moeda for o Banco Central, mais sólida será a sua imagem institucional (Blinder, 1996).

Segundo Rogoff (1985), as sociedades podem experimentar melhores condições econômicas quando designam um dirigente do Banco Central que atribua mais importância à estabilidade de preços do que ao nível de emprego, o que reduz significativamente, com sua imagem, problemas de inconsistência temporal do Banco.

Cukierman (2000, p.3) observa que existe “[...] uma correlação positiva entre controle de inflação e transparência da política monetária”, ao passo que a redução generalizada da inflação possibilitou, na visão de Winkler (2000), fosse percebida a importância crescente da transparência. Neste caso, foi assinalado que o interesse ampliado da literatura acadêmica pelo seu papel, na formulação e condução da política monetária, reflete a atenção cada vez maior que os bancos centrais têm reservado à comunicação de sua política monetária.

O estabelecimento de uma regra monetária previamente comunicada, a transparência, o cumprimento do anunciado, a prestação de contas à sociedade e a autonomia do Banco Central seriam elementos que concorreriam para o aumento de confiança na consecução da missão de manter a moe-

da estável, fortalecendo a credibilidade na Autoridade Monetária (Blinder *et al.*, 2001). Autonomia na esfera operacional para cumprimento de metas anunciadas tem como contrapartida o aumento de responsabilidade, implicando maior transparência e prestação de contas em relação ao alcance das aludidas metas, o que aumenta a credibilidade na atuação do Banco, fortalece sua imagem institucional e legitima sua autonomia operacional.

3 Metodologia

3.1 População e amostra

A população do presente estudo é constituída do conjunto de especialistas de todas as instituições financeiras reguladas pelo Banco Central do Brasil que atuam em áreas operacionais, tais como Tesouraria ou Operações de Mercado Aberto, ou seja, os responsáveis pela realização de pesquisas econômico-financeiras promovidas pelas aludidas instituições financeiras.

A amostra é não-probabilística, tendo sido selecionada com base no critério de acessibilidade e conveniência. Ela foi constituída por 32 especialistas de mercado, ligados à área operacional ou de pesquisa, de quatro instituições bancárias consultadas. Na medida em que a MEE exige amostra cujo tamanho não pode ser inferior a 100 observações, empregou-se simulação de Monte Carlo para ampliar o tamanho da amostra. Nesse contexto, os dados da amostra de conveniência, do estudo sobre transparência e imagem institucional do Banco Central, constituída de 32 observações, possibilitaram a geração de amostra simulada, com distribuição *lognormal*, de 256 observações, conforme metodologia sugerida por Vieira (2005).

3.2 Coleta de dados

Os dados foram coletados por intermédio de questionário estruturado auto-administrado, enviado por correio eletrônico aos respondentes potenciais. O questionário compunha-se de dois tipos de questões fechadas, tendo em vista o objetivo de tra-

tamento dos dados com RL e MEE. O primeiro conjunto de questões fechadas empregou escala Likert, de cinco alternativas de resposta, variando de 'discordo totalmente' a 'concordo totalmente'; o segundo grupo de questões fechadas apresentou alternativa dicotômica de resposta. As questões dicotômicas foram formuladas com o objetivo precípua de se empregar regressão logística. A coleta de dados ocorreu no período de 17 de agosto a 20 de setembro de 2006.

3.3 Variáveis observadas

O questionário estruturado continha 12 questões relacionadas à transparência e à imagem da Autoridade Monetária. Cada questão do questionário estruturado gerou uma variável observada. As variáveis e seu significado encontram-se descritos abaixo:

- V1: Transparência quanto a critérios empregados para definir a meta para taxa SELIC;
- V2: Qualidade do conteúdo técnico dos documentos publicados pelo BACEN, tais como Ata do COPOM e Relatório de Inflação;
- V3: Qualidade gráfica dos documentos divulgados pelo BACEN;
- V4: Clareza das estatísticas econômicas divulgadas pelo BACEN;
- V5: Argumentos convincentes para decisões do COPOM;
- V6: Opinião positiva do mercado em relação ao BACEN;
- V7: Contribuição do BACEN para o bem-estar social;
- V8: Mercado respeita decisões do BACEN;
- V9: Prestação anual de contas convincente pelo Presidente do BACEN;
- V10: BACEN cumpre o anunciado;
- V11: Imagem do Banco Central; e
- V12: Prestígio dos dirigentes do BACEN no mercado.

As variáveis V_{11} e V_{12} são dicotômicas. Foram

consideradas duas questões dicotômicas para registrar a percepção do mercado acerca do Banco Central, partindo-se da premissa de que nem sempre o respondente expressa sua verdadeira opinião quando é inquirido por instituição que lhe monitora diretamente e lhe solicita diretamente que opine sobre a imagem dela. Na medida em que há fortíssima correlação positiva entre imagem do Banco Central e prestígio de seus dirigentes, julgou-se prudente incluir questão dicotômica sobre prestígio de seus dirigentes que pudesse, eventualmente, substituir aquela diretamente relacionada à imagem.

3.4 Tratamento dos dados

O tratamento dos dados foi realizado com estatística descritiva e simulação, empregando-se RL e MEE para avaliação dos modelos hipotéticos. No caso da RL, utilizou-se o programa estatístico SPSS 13.0; no caso da MEE, foi empregado o programa estatístico AMOS 4.0.

4 Resultados

4.1 Regressão Logística

O primeiro resultado digno de nota foi o fato de a variável categórica dicotômica Imagem do Banco Central (V_{11}) apresentar variância zero, uma vez que todos os respondentes consideraram sua imagem sólida. Na realidade, a variância nula atesta a possível inconsistência que pode ser produzida quando se deseja mensurar um construto com variável observada única.

Embora a imagem do Banco Central e o prestígio dos responsáveis por sua direção não apresentem o mesmo significado, uma vez que na imagem está incluída a percepção que se tem acerca da atuação do corpo funcional de carreira, além da presença e diretoria, bem como elementos de sua identidade visual, empregou-se, na RL, enquanto *proxy* da variável dependente "Imagem do Banco Central" (V_{11}), a variável observada "Prestígio dos dirigentes do BACEN" (V_{12}), segundo estudo de Rogoff (1985).

A estimação do modelo de RL foi realizada pelo método *Stepwise (Forward)*, ou seja, ela foi conduzida passo a passo, com inclusão de uma variável a cada passo.

A base para testes de um modelo logístico é o *log likelihood* (LL), que representa o logaritmo da verossimilhança e varia de 0 a menos infinito. Em geral, os programas estatísticos não apresentam o próprio LL, mas o *log likelihood* multiplicado por -2 , dado que, enquanto o *log likelihood* é negativo, $-2 \log likelihood$ é positivo. Na medida em que a estatística $-2LL$ apresenta distribuição que se aproxima da *qui-quadrada* (χ^2), ela é empregada para avaliar a significância da RL. O teste da razão de verossimilhança é um teste de significância da diferença entre a estatística $-2LL$ para o modelo do pesquisador e a estatística $-2LL$ para o modelo reduzido que é constituído tão-somente de intercepto (Menard, 2002).

A Tabela 1 exhibe as principais estatísticas que resultaram da aplicação de RL aos dados, considerando o método de seleção de variáveis supracitado.

Para o modelo que apresenta apenas intercepto, $-2LL$ é, em nosso estudo, igual a 35,9891 ($6,749 + 29,2401$). Quando se inclui a variável V_8 , $-2LL$ é reduzido para 29,2401, o que significa uma redução de 6,749; quando a variável V_1 é incluída no modelo, $-2LL$ reduz-se, uma vez mais, situando-se ao nível de 24,330, o que significa diminuição absoluta de 4,9101. Considerando o modelo com duas variáveis e intercepto, há redução de $-2LL$ de 11, 659 ($6,749+4,9101$), com $p \leq 0,05$. A redução de $-2LL$ atesta que, já que inexistente magnitude mínima recomendada, o modelo com duas variáveis (V_8 e V_1) é superior ao que considera tão-somente V_1 como variável do modelo (Tabela 1).

Paralelamente, a estatística $-2LL$ mensura o quão pobremente o modelo prediz a variável dependente e, quando o nível de significância é menor ou igual a 0,05 ($p \leq 0,05$), rejeita-se a hipótese nula de que as variáveis independentes não tornam melhor a predição da variável dependente na regressão logística (Tabela 1).

Tabela 1
Regressão Logística – Método *Stepwise (Forward)*.

Nº de Variáveis na Equação	1	2
Variáveis na Equação	V_8	$V_1; V_8$
Step	1	2
-2LL	29,241	24,330
R ² de Cox & Snell	0,190	0,305
R ² de Nagelkerke	0,282	0,452
Hosmer & Lemeshow		
χ^2	0,609	0,690
g.l	1	5
Sig	0,435	0,984
Teste dos Coeficientes		
χ^2	6,749	11,659
g.l	1	2
Sig.	0,009	0,003
Total de Acertos (%)	78,1	84,4

Fonte: Cálculo dos autores.

A estatística R^2 de Cox & Snell pode ser interpretada como o R^2 da regressão múltipla, embora não alcance valor máximo de 1. A estatística R^2 de Nagelkerke modifica o coeficiente R^2 de Cox & Snell por seu valor máximo, objetivando atingir uma medida que varie entre 0 e 1. As estatísticas R^2 de Cox & Snell e R^2 de Nagelkerke exibem, no estudo em tela, melhora quando se considera o modelo com 2 variáveis (Tabela 1).

O teste de bondade de ajustamento, de Hosmer e Lemeshow, é um teste χ^2 de excelência do ajustamento. Quando o valor da χ^2 não apresenta

significância estatística ($p > 0,05$), deve-se aceitar a hipótese nula de que não há diferença entre os valores preditos e os observados. Nesse contexto, o modelo com duas variáveis (V_8 e V_1) exibe boa qualidade de ajustamento.

O percentual de observações corretamente classificadas pelo modelo, aumentaram de 78,1% para 84,4%, quando são consideradas as variáveis V_8 e V_1 no passo 2 (Tabela 1).

Os coeficientes de regressão logística e o intercepto estão registrados na Tabela 2.

Tabela 2

Variáveis na Equação.

	B	S.E.	Wald	Gl	Sig	EXP (B)
Step1						
V8		1,794	0,838	4,581	1	0,032
6,013						
Intercepto	-4,883	1,880	6,750	1	0,009	0,008
Step2						
V1	1,753	0,899	3,797	1	0,050	5,769
V8	2,186	1,034	4,475	1	0,034	8,903
Intercepto	-9,545	3,654	6,824	1	0,009	0,000

Fonte: Cálculo dos autores.

A significância dos coeficientes das variáveis independentes é testada com a estatística Wald, que constitui a razão quadrática entre o coeficiente B e o erro padrão, apresentando, neste caso, distribuição χ^2 . Testa-se a hipótese nula de que o coeficiente é zero; quando o nível de significância é menor ou igual a 5% ($p \leq 0,05$), a hipótese é rejeitada. Logo, o intercepto e os coeficientes angulares do modelo hipotético do estudo são estatisticamente significativos (Tabela 2).

Selecionou-se, para fins de análise e de confrontação com os resultados obtidos por meio da modelagem de equações estruturais, o modelo do passo 2, constituído de intercepto e das variáveis V_8 e V_1 (Tabela 2).

Assim, a variável dependente “Prestígio dos dirigentes do Banco Central no mercado”, que está representando a imagem do Banco Central, é influenciada pela variável independente “Transparência quanto a critérios empregados para definir a meta para taxa SELIC” (V_1) e pela variável independente “Mercado respeita as decisões do Banco Central” (V_8).

Na medida em que são válidas as seguintes igualdades:

$$\ln [P/(1 - P)] = \ln (\text{chance}) = \text{logit} (P) \quad (10)$$

Sabendo-se que:

$$\text{logit} (P) = b_0 + b_1X_1 + b_2X_2 \quad (11)$$

$$\ln [P/(1 - P)] = -9,545 + 1,783V_1 + 2,186V_8 \quad (12)$$

$$\text{logit} (P) = -9,545 + 1,783V_1 + 2,186V_8 \quad (13)$$

O *logit* (P) altera 1,783 para uma unidade de variação em V_1 , independentemente do nível de V_1 , caracterizando linearidade entre o *logit* e V_1 . O mesmo pode ser estendido à relação entre o *logit* e V_8 .

Convém seja relacionada probabilidade ao *logit*. Para tanto, vale considerar as relações abaixo.

$$\ln [P/(1 - P)] = -9,545 + 1,783V_1 + 2,186V_8 \quad (14)$$

Logo, tem-se que:

$$e^{\ln[P/(1 - P)]} = e^{-9,545 + 1,783V_1 + 2,186V_8} \quad (15)$$

O anti-logaritmo do logaritmo de um valor iguala o próprio valor, ou seja:

$$P/(1 - P) = e^{-9,545} \cdot e^{1,783V_1} \cdot e^{2,186V_8} \quad (16)$$

Caso se quisesse uma expressão para a própria probabilidade, ter-se-ia, então:

$$P = e^{-9,545 + 1,783V_1 + 2,186V_8} / (1 + e^{-9,545 + 1,783V_1 + 2,186V_8}) \quad (17)$$

Observe-se que inexistente linearidade entre o logaritmo da chance (*logit*) e a probabilidade, tornando muito mais complexo o problema de interpretação dos coeficientes de regressão logística, já que o efeito das variáveis independentes varia com seu valor e o nível de probabilidade. Neste caso, mudança unitária na variável independente impacta mais a probabilidade, a níveis mais reduzidos da variável independente e de P, do que quando seus níveis são elevados (Liao, 1994).

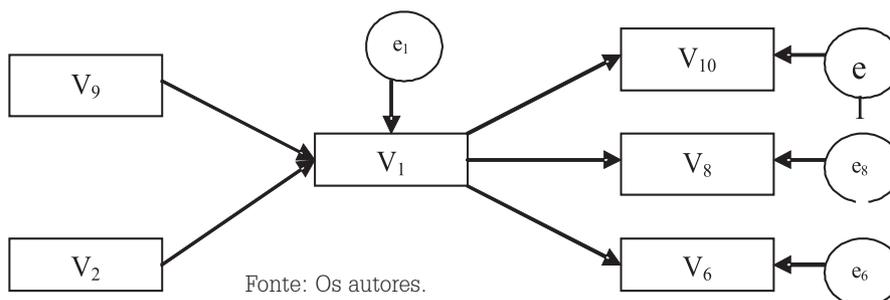
Independentemente da interpretação dos coeficientes de RL, inexistente dúvida quanto ao sinal que assume, nem quanto às variáveis que exercem impacto sobre a variável representativa da Imagem Institucional do Banco Central. A imagem institucional sofre, segundo o modelo de RL, impacto da transparência e da confiança que a Autoridade Mo-

netária construiu com adoção do regime de metas de inflação e com a simultânea mudança de regime cambial, que passou de taxas fixas de câmbio para flutuantes, refletida na variável observada Mercado Respeita decisões do Banco Central. Logo, o fortalecimento da transparência repercute positivamente sobre a imagem institucional do Banco Central.

4.2 Modelagem de Equações Estruturais

O procedimento de simulação permitiu fossem removidas todas as influências adversas à obtenção de um ajustamento de excelência, garantindo a aleatoriedade das amostras; elevando o seu tamanho; e assegurando dados com distribuição *log-normal*. Construiu-se amostra aleatória simulada de 256 observações. Ou seja, foram criadas as condições ideais para ajustamento do modelo em MEE. O diagrama de caminho da Figura 1 ilustra o modelo de análise de caminho que foi testado com MEE, considerando as seguintes variáveis observadas:

- V1: Transparência quanto a critérios empregados para definir a meta para taxa SELIC;
- V2: Qualidade do conteúdo técnico dos documentos publicados pelo BACEN, tais como Ata do COPOM e Relatório de Inflação;
- V6: Opinião positiva do mercado em relação ao BACEN;
- V8: Mercado respeita decisões do BACEN;
- V9: Prestação anual de contas convincente pelo Presidente do BACEN;
- V10: BACEN cumpre o anunciado;



Fonte: Os autores.

Figura 1

Impacto da Transparência na Imagem Institucional do Banco Central.

Cabe observar que o modelo não contempla nenhuma variável dicotômica, uma vez que a MEE supõe não somente variáveis contínuas, mas também normalidade *multivariada*. Convém analisar, inicialmente, os índices de ajustamento do modelo (Tabela 3). Conforme se pode observar, todos os índices de ajustamento ficaram em patamar superior ao mínimo recomendado, atestando ajustamento global de qualidade muito satisfatória.

Tabela 3

Resultados de Ajustamento (AMOS 4.0).

Casos incluídos na análise: 256	
Graus de Liberdade	8
Qui-Quadrado	17,005
Significância	0,030
CMIN/DF	2,126
GFI	0,980
AGFI	0,948
RMSEA	0,066

Fonte: Cálculo dos autores.

A MEE apresenta limitações que não podem ser ignoradas quando se avalia o modelo hipotético. Uma importante restrição está relacionada ao fato de que o modelo estrutural pode exibir ajustamento de excelência, mesmo quando todos ou a maioria de seus principais parâmetros não apresentam significância estatística, ou seja, quando os parâmetros são estatisticamente iguais a zero. Conforme atesta a Tabela 4, todas as estimativas de parâmetro exibiram significância estatística.

Tabela 4

Pesos de Regressão (AMOS 4.0)

Caminho	Peso de Regressão	S.E.	C.R.
$V_1 \leftarrow V_2$	3,345	1,007	3,322
$V_1 \leftarrow V_9$	7,602	1,800	4,223
$V_8 \leftarrow V_1$	2,482	0,344	7,212
$V_{10} \leftarrow V_1$	4,523	1,279	3,535
$V_6 \leftarrow V_1$	3,823	0,844	4,531

Fonte: Cálculo dos autores.

As estimativas dos parâmetros apresentam significância estatística e revelam *insight* importante. A transparência na definição da taxa SELIC exerce impacto positivo sobre três variáveis representativas da imagem do Banco Central, quais sejam: cumprimento do anunciado; respeito às decisões do Banco Central; e opinião positiva em relação ao BACEN. O impacto mais pronunciado da transparência é sobre o cumprimento do anunciado. Todavia, o impacto da transparência é exercido sobre variáveis representativas de três dimensões de percepção. Assim, quanto mais transparente for a definição da taxa SELIC, mais intensa será a percepção de que o Banco Central cumpre o anunciado, mais forte será a percepção de que a opinião sobre a Autoridade Monetária é positiva e mais sólida é a percepção de que suas decisões são respeitadas. É inquestionável, então, o ganho para a imagem institucional que acarreta o aumento de transparência.

Convém observar que, não fosse a aplicação de simulação, os resultados da MEE não seriam gerados, uma vez que a amostra original de 32 casos não possibilitaria a obtenção de resultados consistentes, mesmo que houvesse convergência.

5 Considerações finais

Ambos os modelos mostram que a imagem institucional do Banco Central sofre impacto positivo da transparência. Todavia, obtém-se riqueza de *insight* diferente dependendo da ferramenta estatística utilizada.

No caso da RL, o *insight* é menos rico, pois o coeficiente da regressão logística carece de métrica significativa, embora seu sinal constitua informação essencial. Afirmativas acerca dos efeitos das variáveis independentes sobre mudanças em logaritmo da chance nada revelam quanto à relevância da influência de cada variável independente sobre a probabilidade.

A interpretação da relevância dos coeficientes de regressão logística fica facilitada com sua transformação, uma vez que permitem que seja avaliado seu impacto sobre a chance em lugar do loga-

ritmo da chance da variável dependente. Todavia, os impactos referem-se à chance; não dizem respeito diretamente à probabilidade.

A dificuldade para interpretação dos coeficientes de regressão logística pode ser compensada com modelos mais parcimoniosos, amostras menores, e, conseqüentemente, orçamentos de pesquisa menores, comparativamente aos necessários para implementar pesquisa com MEE, embora não se deva ignorar o nível de *insight* que modelos bem especificados em MEE podem gerar.

Nas ciências comportamentais, os pesquisadores estão freqüentemente interessados em estudar construtos teóricos que não podem ser observados diretamente. Dadas características extremamente desejáveis, tais como considerar a existência de erro em variáveis independentes e permitir a mensuração de relações entre variáveis observadas (ou manifestas) à variável não observada (ou latente), a MEE tornou-se metodologia de uso difundido para teste de hipóteses. De fato, a MEE possibilita a compreensão de padrões complexos de inter-relações entre variáveis, exibindo indubitável capacidade de gerar *insight* de valor inestimável, não obstante apresente restrições que não podem ser olvidadas. Inicialmente, para que o modelo seja válido, é fundamental que apresente raízes profundas na teoria, pois,

com base no mesmo grupo de variáveis, pode-se especificar uma variedade de modelos alternativos, que, embora apresentando bons níveis de ajustamento, carecem de fundamentos conceituais sólidos.

Na realidade, um modelo estrutural pode exibir bom ajustamento, sem que seus parâmetros apresentem significância estatística, ou seja, sejam estatisticamente diferentes de zero, conduzindo o pesquisador menos experiente a extrair conclusões de um modelo desprovido de significado.

As restrições não se limitam a considerações sobre ajustamento, pois uma hipótese fundamental em MEE é a existência de normalidade *multivariada*, não sendo suficiente que as variáveis individuais exibam normalidade, pois, embora necessária, a normalidade de variáveis individuais não assegura normalidade conjunta.

Na medida em que o volume necessário de recursos aumenta à proporção que cresce o tamanho da amostra, e considerando que, em estudos com MEE, amostras pequenas apresentam maior probabilidade de violar a hipótese de normalidade e gerar estimativas de parâmetros sem significância estatística, quando há expressiva limitação de recursos, a RL torna-se mais indicada, pois apresenta menor risco de resultados mal-sucedidos, ainda que não produza tanto *insight* quanto a MEE.

Referências

- ARBUCKLE, J.L.; WOTHKE, W. *AMOS 4.0 user's guide*. New York: SmallWaters, 1999.
- BLINDER, A.S. Central banking in a democracy. *Federal Reserve Bank of Richmond Economic Quarterly*, v. 82, n. 4, 1996.
- _____. Central Bank credibility: why do we care? How do we build it? *NBER Working Paper Series*, n. 7161, p.1-23, 1999a.
- _____. *Bancos Centrais: teoria e prática*. São Paulo: Editora 34, 1999b.
- BLINDER, A.S. et al. How do Central Banks talk? *Geneve Reports on the World Economy*, n. 3, p. 1-122, 2001.
- BYRNE, M.B. *Structural Equation Modeling with AMOS: basic concepts, applications, and programming*. New Jersey: Lawrence Erlbaum, 2001.
- CUKIERMAN, A. Establishing a Reputation for Dependability by Means of Inflation Targets. *Economics of Governance*, v. 1, n. 1, p.1-35, 2000.

- CYSNE, R.P. e SIMONSEN, M.H. *Macroeconomia*. 2ª.ed. São Paulo:Atlas, 1995.
- FRIEDMAN, M. Inflação e desemprego: a novidade da dimensão política. *Literatura Econômica*, v.7, n. 3, p.381-408, 1985.
- HAIR, J. F. et al. *Análise multivariada de dados*. Porto Alegre: Bookman, 2005.
- HU, L.; BENTLER, P.M. *Evaluating model fit*. In: Structural Equation Modeling: concepts, issues, and application, Hoyle, R.H. (ed.), London: Sage, 1995.
- KLINE, R.B. *Principles and practice of Structural Equation Modeling*. New York: Guilford, 2005.
- LIAO, T.F. *Interpreting probability models: logit, probit, and other generalized linear models*. London: Sage, 1994.
- MENARD, S. *Applied logistic regression analysis*. London: Sage, 2002.
- MENDONÇA, H.F. Transparência, condução da política monetária e metas para inflação. *Nova Economia*, v.16, n.1, p.175-198, 2006.
- RAYKOV, T.; MARCOULIDES, G.A. *A first course in Structural Equation Modeling*. New Jersey: Lawrence Erlbaum, 2000.
- ROGOFF, K. The optimal degree of commitment to an intermediate monetary target. *The Quarterly Journal of Economics*, v.100, n.4, p.1169-1189, 1985.
- VIEIRA, P.R.C. O emprego do critério de falseamento e a otimização de resultados de survey: a simulação de Monte Carlo aplicada a estudo sobre imagem e reputação do Banco Central. In: Encontro da ANPAD, 24., 2005, Brasília. *Resumo de Trabalhos ENANPAD*.Brasília: ANPAD, 2005, p. 1-15.
- WINKLER, B. Which kind of transparency? On the need for clarity in monetary policy-making. *European Central Bank Working Paper*, n. 26, p.1-31, 2000.