

Variáveis Macroeconômicas e o Retorno Real do Ibovespa: Uma avaliação Linear e Não-Linear

Marcelo S. Portugal¹

Pedro Lutz Ramos²

RESUMO

O artigo testa nove variáveis macroeconômicas (Preço de Commodities, Taxa de Desemprego, Inflação, Agregados Monetários, Taxas de juros, Relative Money Market Rate (RMM), Produção Industrial, Hiato do Produto (GAP) e Taxa de juros dos EUA) contra o retorno real do Ibovespa, empregando regressões lineares, como tradicional na literatura, e modelos de mudança de regime markoviana (MSM), para avaliar melhor o impacto e o poder de previsão do retorno sob uma economia tão perturbada por planos econômicos e crises financeiras. Além disso, realizamos uma rigorosa avaliação do poder preditivo através de testes dentro e fora da amostra, incluindo avaliações dos coeficientes estimados defasados, critérios de Informação de AIC e BIC, Razões de Erro Quadrático Médio e o Erro Absoluto Médio e testes de encompassing de Diebold e Mariano (1995), de Clark e Mccracken (2001) e de Mccracken (2007), combinados aos novos valores assintóticos de Clark e Mccracken (2001, 2004). Os resultados indicam que o retorno do Ibovespa se ajusta melhor com modelos de mudança de regime, possuindo dois regimes, e que a variável Hiato do Produto destaca-se por ser a mais significativa e de maior poder de previsão, tanto nos modelos lineares como nos não lineares. Ainda, destacamos que sob algumas restrições as variáveis RMM, Taxa de Juros dos EUA, M1 agregaram informação preditiva aos modelos de previsão. Por fim, produção industrial não apresentou capacidade preditiva.

Palavras-Chave: Modelos Markov-Switching Previsão Variáveis Macroeconômicas Retorno Real Ibovespa.

ABSTRACT

This paper tests nine macroeconomic variables (Commodity Price, Unemployment Rate, Inflation, Money Stock, Interest Rate, Relative Money Market Rate (RMM), Industrial Production, Output Gap (GAP) and United States Interest Rate) versus the Ibovespa Real Stock Return, with linear models, as in traditional literature, and with Markov Switching Models, to gauge the impact and the predictive power of the assumption of an economy so troubled by economic plans and financial crises. In addition, we conducted a rigorous predictive ability evaluation by testing in-sample and out-of-sample, including a lagged coefficient estimated evaluation, information criteria of Akaike and Schwarz, Mean-square Error, Absolute Mean Error and encompassing tests of Diebold e Mariano (1995), Clark e Mccracken (2001) and Mccracken (2007) combined with the new asymptotic values of Clark e Mccracken (2001,2004). The results indicated that the Ibovespa has two states and the Output Gap variable stands out for being the most significant variable and with the greatest predictive ability for both linear and nonlinear models. Moreover, we emphasize that under some restrictions on the variables RMM, U.S. Interest Rate, M1 predictive information to forecasting models. Finally, industrial production showed no predictive ability.

Key-word: Markov-Switching Models Forecast Macroeconomic Variables Real Return Ibovespa.

JEL: C53, E44, G17

¹ Professor de economia da UFRGS e pesquisador do CNPQ.

² Economista da Federação do Comércio de Bens e Serviços do Estado do Rio Grande do Sul (Fecomércio-RS) e Mestre em economia aplicada pela UFRGS.

1. INTRODUÇÃO

A descoberta de variáveis macroeconômicas (VM) capazes de auxiliar na previsão do retorno do mercado acionário (RA) sempre despertou a atenção dos agentes por possibilitar um melhor desempenho no gerenciamento de investimentos financeiro. Em estudos acadêmicos empíricos, essas relações tem sido alvo de bastante discussão, já que não há um consenso sobre o tema, por não conseguir verificar um padrão do impacto das diferentes VM sobre o retorno, quando modificamos o país em análise, ou quando aplicamos diferentes técnicas com as mesmas variáveis sobre o retorno.

Assim, surgiu uma longa literatura sobre o assunto, que se inicia na década de 70, com Reilly, Jonson e Smith (1971); Oudet (1973); Lintner (1975); Bodie (1976); Jaffee e Mandelker (1976); Nelson (1976); Fama e Schwert (1977); e outros, discutindo se os preços das ações eram realmente protegidas (*Hedge*) da inflação. Os resultados indicavam que havia uma relação da inflação esperada, da inflação verificada, dos agregados monetários e da taxa de juros sobre o retorno no mercado estadunidense, mas ao contrário do que a teoria monetária previa (Fischer, 1930), a inflação era negativamente relacionada. Logo após essas diversas constatações, Fama (1981) e Geske e Roll (1983) criam hipóteses para justificar esse resultado adverso sobre a teoria, ficando conhecidas como *Hipótese de Fama*, tratando a relação como espúria, e *Hipótese Fiscal*, que apresenta um longo caminho através da política monetária e fiscal para apontar o motivo da relação negativa. Todavia, é verificado em Pearce e Roley (1984), com dados semanais, que na grande parte das vezes que houve aumento da base monetária gerou-se redução no retorno, indicando uma relação diferente da encontrada por Fama (1981).

Mais tarde, ainda dentro dessa linha de pesquisa, James, Koreisha e Parth (1985) e Lee (1992) utilizavam a metodologia VAR (*Vector Autoregressive*) com testes de causalidade, e mais uma vez encontram que o retorno é negativamente relacionado com a inflação. No entanto, cada um dos trabalhos indica resultados opostos, com o primeiro apontando a *Hipótese*

de Fama, enquanto o segundo encontra a *Hipótese Fiscal*, como mais adequada aos dados estadunidenses. Então, na tentativa de harmonizar os resultados, além de estender a metodologia à diversos países desenvolvidos e em desenvolvimento (incluindo o Brasil), Terra (2006) conclui que não existe uma hipótese universal compatível a todos os países, tendo cada país uma hipótese mais adequada.

Alternativamente, com outro propósito, apareceram diversos trabalhos com o objetivo de descobrir quais variáveis macroeconômicas poderiam ajudar na previsão, sem que houvesse necessariamente um modelo teórico que justificasse a composição dos modelos. Dessa forma, surgiram artigos que testavam, além de inflação e agregados monetários, taxa de juros (Breen, Glostene e Jagannathan (1989), Chen (1991) e Asprem (1989)); taxa de desemprego ou variáveis do mercado de trabalho (Jagannathan e Wang (1993), Jagannathan, Kubota e Takehara (1998)³ e Boyd, Jagannathan e Hu (2002)); produção industrial (Pearce e Roley (1985), Balvers, Cosimano e Mcdonald (1990), Pesaram e Timmermann (1995), Chan, Karceski e Lankonishok (1998) e Flannery e Protopapadakis (2002)); e taxa de juros dos EUA no mercado de outros países (Conover, Jensen e Johnson (1999)).

Entretanto, os resultados dos artigos acima nem sempre entravam em acordo, mostrando não haver um resultado padronizado, mesmo quando testando somente na economia estadunidense. Por exemplo, Chan, Karceski e Lankonishok (1998) e Flannery e Protopapadakis (2002) não encontram evidências de que a produção industrial e agregados monetários poderiam ajudar na previsão ou na determinação do retorno, enquanto que Pearce e Roley (1984, 1985), Balvers, Cosimano e Mcdonald (1990) e Pesaram e Timmermann (1995) evidenciam o contrário. Dessa forma, Rapach, Wohar e Rangvid (2005), RWR(2005), desenvolvem um estudo com objetivo de esclarecer todos esses desencontros e testam 10 VM⁴ de 12 países

³ Resultado obtido a partir de dados japoneses.

⁴ *Relative Money Market Rate; Relative Treasury Bill Rate, Relative Government Bond Yield, Term Spread*, taxa

desenvolvidos⁵, através de diversos testes de previsão dentro e fora da amostra, que possibilitaram uma avaliação mais rigorosa. O resultado mostra que as VM que tinham capacidade de previsão em todos os países foram aquelas vinculadas à taxa de juros, sendo que em três países (EUA, Holanda e Noruega) a taxa de inflação também foi importante. Ademais, em horizontes mais longos de previsão, agregados monetários e *term spread* mostraram-se com capacidade de previsão na maioria dos países. Por fim, produção industrial e desemprego não apresentaram capacidade preditiva.

O que podemos verificar com o trabalho acima é que essas relações devem ser pesquisadas individualmente em cada país, pois mesmo que haja certo padrão, peculiaridades, como a inflação nos EUA, Holanda e Noruega, podem ser importantes na previsão dessas variáveis. Ademais, observamos como é importante uma avaliação rigorosa da previsão, visto que o trabalho de RWR (2005) aponta resultados em relação à produção industrial e desemprego, que destoam de grande parte da literatura.

Já em países em desenvolvimento podemos destacar Wangbangpo e Sharma (2002), Gunasekarege, Pisedtasalasai e Power (2004), Abugri (2008), Gay (2008), Adrangi, Chatrath e Sanvicente (2000); Nunes, Costa Jr e Meurer (2005); De Medeiros e Ramos (2004); Terra (2006) e Caselani e Eid (2008); que também apresentam divergências. O primeiro, por exemplo, verifica se os mercados da Indonésia, da Malásia, das Filipinas, de Singapura e da Tailândia são afetados pela taxa de juros, pelo crescimento do PIB, pela taxa de câmbio e pelos agregados monetários, mas conforme o país o sinal dos coeficientes estimados modificam-se. Em Adrangi, Chatrath e Sanvicente (2000), encontraram uma relação negativa do retorno com a inflação no Brasil, porém esse aplica uma amostra de 1986 até 1997, onde a variável

de inflação, taxa de crescimento da produção industrial, agregados monetários (M1, M2 ou M4) e desemprego

⁵ Bélgica, Canadá, Dinamarca, França, Alemanha, Itália, Japão, Holanda, Noruega, Suécia, Reino Unido e Estados Unidos.

inflação troca de comportamento em 1994 e passa por seis planos econômicos antiinflacionários, incluindo troca de moeda. Em Medeiros e Ramos (2004) é estudado os fatores que afetam a volatilidade do Ibovespa, e encontra uma relação positiva das variáveis S&P 500, PIB e taxa de câmbio e uma relação negativa das variáveis taxa de juros e risco-país com o retorno. Todavia, esse trabalho não usa variáveis defasadas, o que impede de afirmar se essas variáveis têm poder de previsão. O último trabalho indica haver uma relação positiva do RA com a taxa de juros real e negativa com a produção industrial brasileira, sendo que o mercado americano não afeta sistematicamente o mercado brasileiro.

Já em Nunes, Costa Jr e Meurer (2005) e Terra (2006), tentam encontrar se as hipóteses de Fama, Gerske e Roll e a de causalidade reversa⁶ estão presentes nos dados empíricos brasileiros. Ambos encontram evidências sobre a relação negativa da taxa de juros e taxa de inflação defasadas com o mercado acionário. Contudo, Terra (2006) afirma que a atividade econômica afeta o mercado acionário enquanto que Nunes, Costa Jr e Meurer (2005) afirmam o contrário. Esse último artigo mostra que a exterior afeta o mercado interno com o spread do *C-Bonds* e taxa de câmbio real.

Assim, como podemos observar, no caso de países em desenvolvimento, principalmente o Brasil, não possui uma resposta a pergunta se variáveis macroeconômicas podem prever o retorno, e principalmente, o impacto de cada uma delas é desconhecido, por ignorarem as mudanças radicais que essas variáveis sofreram na história.

Dessa forma, estamos propondo um trabalho que avalie a capacidade preditiva de nove variáveis macroeconômicas sobre o retorno real do Índice da Bolsa de Valores de São Paulo – IBOVESPA, com modelos lineares e modelos de mudança de regime markoviana, trazendo o rigor do método aplicado em RWR (2005). O objetivo de usar modelos de mudança de regime é conseguir preservar o impacto das variáveis

⁶ Hipótese a qual o mercado acionário impacta as variáveis macroeconômicas.

macroeconômicas sobre o retorno, quando foi sistematicamente afetado por crises e por mudanças estruturais da economia brasileira⁷. Com isso tentamos esclarecer quais dessas relações são válidas para a economia brasileira, por entender que não há uma resposta para esse questionamento, principalmente por os trabalhos ignorarem os efeitos da crise ou efeito das mudanças estruturais da economia. Além disso, aproveitando o escopo dos resultados, avaliaremos questões divergentes como o impacto da inflação sobre o retorno real.

Os nossos resultados indicam grande capacidade preditiva da variável hiato do produto em modelos lineares e modelos de mudança de regime, contudo o ajuste dos modelos de mudança de regime são melhores. *Relative Money Market Rate*, inflação e agregado monetários apresentaram capacidade preditiva somente em modelos de mudança de regime, porém os dois últimos somente em modelos que contém a variável GAP.

2. MODELO ECONOMÉTRICO

A sessão de metodologia tem o objetivo de apresentar as técnicas econométricas e as séries de tempo empregadas no estudo. Na primeira parte apresentaremos, de forma geral, o mecanismo utilizado para testar a nossa hipótese, ou seja, quais serão os critérios empregados para mostrar a capacidade das variáveis macroeconômicas preverem o retorno. Já na segunda parte, apresentaremos a estimação e a previsão dos modelos lineares e não-lineares, com a metodologia de mudança de regime. Por fim, na terceira parte, apresentaremos as séries temporais utilizadas e o teste de estacionariedade Dickey-Fuller Aumentado de cada uma delas.

2.1 Mecanismo empregado para testar a hipótese

O trabalho tem o objetivo de encontrar evidências sobre o poder de previsão de variáveis macroeconômicas sobre o retorno do

índice da bolsa de valores de São Paulo. Dessa forma, nossa metodologia é baseada em RWR (2005), que verificam comparativamente se a previsão realizada por modelos configurados com essas variáveis superam os modelos autorregressivos simples. Para tanto, montamos os modelos preditivos aninhados do retorno, em que o modelo restrito é:

$$y_{t+1} = \alpha + \gamma y_t + e_{t+1} \quad (2.1.1)$$

E o modelo não-restrito é:

$$y_{t+1} = \alpha + \beta z_t + \gamma y_t + e_{t+1} \quad (2.1.2)$$

Onde y_t é a primeira diferença do logaritmo do retorno real do IBOVSPA no tempo t , ou seja, é a diferença entre o logaritmo do retorno deflacionado do tempo t e do tempo $t-1$; z_t é a matriz das variáveis macroeconômicas no período t , e e_{t+1} é termo de erro aleatório⁸. Assim, avaliaremos se a inclusão da(s) variável(is) macroeconômica(s) melhora(m) a previsão, indicando, portanto, que essas possuem poder preditivo sobre o retorno. Para avaliarmos dentro da amostra, observaremos o(s) parâmetro(s) da(s) variáveis exógenas(s), como boa parte da literatura, e os critérios de informação AIC e BIC. Fora da amostra, aplicaremos o teste de abarcamento (*encompassing*), de Diebold e Mariano (1995), D&M (1995), o novo teste de abarcamento de Clark e Mccracken (2001), C&M (2001), e o teste de diferença de erros de previsão de Mccracken (2007). Através dessa metodologia, colocaremos como hipótese nula o abarcamento do modelo não-restrito pelo modelo restrito, fazendo com que a rejeição da hipótese nula signifique que o modelo com a variável exógena tem mais informação sobre o futuro que o modelo restrito. Todavia, essas duas metodologias, não se aplicam aos modelos de mudança de regime markoviana (MSM), por que um dos pressupostos feitos para o teste de abarcamento é a exigência que os modelos testados devem se estimados por mínimos

⁷ Muito trabalhos, como Fasolo e Portugal (2004), apontam que a economia brasileira possui mais de um regime em diversas variáveis macroeconômicas.

⁸ α , β e γ são os parâmetros estimados referentes ao intercepto e às variáveis macroeconômicas.

quadrados ordinários (OLS), como segue na citação de C&M (2001, p.88)⁹.

Assim, visto que o MSM é um modelo não-linear que possui parâmetros estimados de variáveis não-observáveis, como veremos à frente, não podemos empregar essa metodologia, (embora tenha sido utilizado por Bessec e Bouadallah (2005)). Para os modelos MSM apenas verificaremos se a Raiz do Erro Quadrático Médio (RMSE) e o Erro Absoluto Médio (MAE) da previsão um passo a frente dos modelos não-restritos são menores que os dos modelos restritos¹⁰. Segue abaixo as fórmulas de cada um dos testes empregados, onde NP é o número observações utilizadas nas previsões um passo a frente, $\hat{u}_{1,t+1}$, é o erro de previsão um passo a frente do modelo restrito, $\hat{u}_{2,t+1}$, é o erro de previsão um passo a frente do modelo não restrito, $c_{t+1} = \hat{u}_{1,t+1} \times (\hat{u}_{1,t+1} - \hat{u}_{2,t+1})$ e $\bar{c} = P^{-1} \times \sum_t c_{t+1}$.

Teste de *Encompassing* de D&M (1995)¹¹:

$$ENC - T = (NP - 1)^{\frac{1}{2}} \times \frac{NP^{-1} \sum_t (\hat{u}_{1,t+1}^2 - (\hat{u}_{1,t+1} \times \hat{u}_{2,t+1}))}{\sqrt{NP^{-1} \sum_t (\hat{u}_{1,t+1}^2 - (\hat{u}_{1,t+1} \times \hat{u}_{2,t+1}))^2 - \bar{c}}} \quad (2.1.3)$$

Teste Novo de *Encompassing* (C&M (2001)):

$$ENC - NEW = NP \times \frac{NP^{-1} \sum_t (\hat{u}_{1,t+1}^2 - (\hat{u}_{1,t+1} \times \hat{u}_{2,t+1}))}{NP^{-1} \sum_t \hat{u}_{2,t+1}^2} \quad (2.1.4)$$

Teste de diferença de Erro Quadrático Médio de Previsão

$$MSE - F = NP \times \left(\frac{\sum_t ((\hat{u}_{1,t+1})^2 - (\hat{u}_{2,t+1})^2)}{\sum_t (\hat{u}_{2,t+1})^2} \right) \quad (2.1.5)$$

Raiz do Erro Quadrático Médio (RMSE)¹²

$$RMSE = \frac{RMSE_2}{RMSE_1} = \sqrt{\frac{NP^{-1} \sum_t \hat{u}_{2,t+1}^2}{NP^{-1} \sum_t \hat{u}_{1,t+1}^2}} \quad (2.1.6)$$

Erro Absoluto Médio (MAE):

$$MAE = \frac{MAE_2}{MAE_1} = \frac{|P^{-1} \sum_t \hat{u}_{2,t+1}|}{|P^{-1} \sum_t \hat{u}_{1,t+1}|} \quad (2.1.7)$$

2.2. Método de Estimação e Previsão nos modelos lineares

O método empregado para a estimação dos modelos lineares é OLS (Ordinary Least

⁹ “Assumption 1. The parameter estimates $\hat{\beta}_{i,t}$, $i = 1, 2$, $t = R, \dots, T$, satisfy $\hat{\beta}_{i,t} - \beta_i^* = B_i(t)H_i(t)$, where $B_i(t)H_i(t)$ equal $(t^{-1} \sum_{j=1}^t q_{i,j})^{-1} (t^{-1} \sum_{j=1}^t h_{i,j})$. Our first assumption is that the parameters must be estimated by OLS. This restriction is imposed to ensure that the statistics in Theorems 3.1-3.3 are asymptotically pivotal.”

¹⁰ Realizamos os testes mesmo acreditando não serem adequados e os publicamos em anexo na Tabela A.3.2.3.2.2.

¹¹ Teste elaborado por Harvey, Leybourne, Newbold, (1998), porém realizado com a metodologia de D&M (1995)

¹² Para o RMSE (e MAE) utilizamos as razões do $RMSE_2(MAE_2)$, do modelo não restrito pelo $RMSE_1(MAE_1)$, do modelo restrito, Assim, caso essa razão seja menor do que um, é por que o Erro Quadrático Médio da Previsão (Erro Absoluto Médio) do modelo com a variável macroeconômica é menor do que o modelo que possui apenas a variável endógena defasada.

Square), estimado com a técnica de HAC¹³ (*Heterokedastic and Autocorrelation Consistent*) com distribuição *Barnett Kernel* com largura de banda travada de escolha automática, técnica apresentando por NEWEY e WEST (1987). Essa abordagem foi empregada com a finalidade de não termos problemas relacionados à heterocedasticidade e autocorrelação serial, seguindo o realizado por RWR (2005). O *software* utilizado foi GRETL na versão 1.7.9.

C&M (2001), mostram que a distribuição assintótica do teste de *encompassing*, quando feito entre modelos aninhados, não segue uma distribuição t-student padrão, como no teste proposto por D&M (1995). Através de simulações de Monte Carlo, os autores demonstram que quando a relação do número de observações usadas para gerar a previsão recursiva um passo à frente (*NP*) pelo número de observações usadas para fazer a primeira previsão um passo a frente (*NR*), $\frac{NP}{NR}$, é modificada, alteram-se os valores assintóticos do teste, causando diagnósticos errados. Como resultado dessa pesquisa, os autores disponibilizaram uma tabela¹⁴ que apresenta os valores assintóticos para cada tipo de teste de *encompassing*, conforme o valor da razão para cada relação $\frac{NP}{NR}$. Dessa forma, utilizamos a previsão recursiva um passo a frente com a razão $\frac{NP}{NR} = 0,4$, a fim de atender a metodologia citada acima.

2.3 Método de Estimação e Previsão nos Modelos de Mudança de Regime Markoviana

Para os modelos de mudança de regime markoviana seguimos a mesma metodologia dos

¹³ Sabemos que ao usar essa metodologia corremos o risco de ter distorções sobre a significância do teste t dos parâmetros estimados, como apresentado por Goetzman e Jorion (1993), Nelson e Kim (1995), e Kirby (1997). Por isso, a avaliação dentro da amostra, não se baseará apenas pelos parâmetros, mas também pelos critérios de informação que são baseados no logaritmo da máxima verossimilhança gerado a partir da otimização do processo de estimação dos parâmetros dos modelos.

¹⁴ Tabela com os valores em anexo

modelos lineares. Contudo, os modelos que nos baseamos é o de HAMILTON (1989), porém com variáveis exógenas e variáveis endógenas defasadas dependente da variável de estado não observável, que segue uma cadeia de Markov de primeira ordem. Por ser uma técnica já amplamente conhecida apenas apresentaremos o modelo empregado e como sua previsão será realizada.

O modelo de mudança de regime markoviano foi desenvolvido por Hamilton (1989) com objetivo conseguir mostrar que o crescimento do PIB dos EUA se comportava de acordo com dois regimes, um de expansão e outro de recessão, atribuído que a média do processo autorregressivo se modificava conforme o estado ou o regime em que essa se encontrava. Essa mudança de regime ocorria conforme uma variável aleatória não-observável, denotada por S_t , que apenas assume os valores 1 e 2, e que é governada por um processo markoviano de primeira ordem com a seguinte probabilidade de transição entre os regimes:

$$Prob[S_t = 1|S_{t-1} = 1] = p_{11} \quad (2.3.1.1)$$

$$Prob[S_t = 1|S_{t-1} = 2] = 1 - p_{11} = p_{12} \quad (2.3.1.2)$$

$$Prob[S_t = 2|S_{t-1} = 2] = p_{22} \quad (2.3.1.3)$$

$$Prob[S_t = 2|S_{t-1} = 1] = 1 - p_{22} = p_{21} \quad (2.3.1.4)$$

ou, de outra forma, onde \mathbf{P} é a matriz de probabilidade de transição para dois regimes

$$\mathbf{P} = \begin{bmatrix} p_{11} & p_{21} \\ p_{12} & p_{22} \end{bmatrix} \quad (2.3.1.5)$$

Além disso, é definido que o processo estocástico de S_t , apresentado acima (3.2.2.1.2-3.2.2.1.4), é estritamente estacionário, ergódico, irreduzível e segue um processo autoregressivo de primeira ordem.

Dessa forma, essa metodologia abriu precedente por não apenas estimar a média de uma equação econométrica com dois regimes,

mas por estimar todos os parâmetros da equação variando conforme o regime em que se encontra. Assim, sob nossa hipótese de que o retorno real do IBOVESPA seria influenciado por variáveis macroeconômicas, e, portanto, sujeito aos ciclos econômicos, estimaremos o seguinte modelo:

$$y_t = c_{s_t} + \phi_{1s_t} x_{t-1} + \phi_{2s_t} x_{t-2} + \dots + \phi_{ps_t} x_{t-p} + \gamma_{1s_t} y_{t-1} + \gamma_{2s_t} y_{t-2} + \dots + \gamma_{ps_t} y_{t-p} + \varepsilon_t \quad (2.2.2.1.6)$$

Em que c_{s_t} , ϕ_{s_t} e γ_{s_t} são os coeficientes estimados e ε_t é o termo de erro, *i. i. d.* $\sim N(0, \sigma^2)$, ambos subordinados ao comportamento da variável S_t , como descrito acima, assumindo existir dois regimes, um de estabilidade e outro de instabilidade. Para estimar esse modelo é aplicado o algoritmo EM apresentado por Hamilton (1989), maiores informações ver o artigo ou Hamilton (1994).

Quanto a previsão, que é recursiva um passo a frente, como nos modelos lineares, é importante destacar que nos MSM é composta da previsão realizada por cada uma das equações de cada regime e ponderada pela previsão da probabilidade de transição um passo a frente, como apresentado por Hamilton (1994).

$$E(y_{t+1} | I_t) = \sum_{j=1}^N P\{S_{t+1} = j | I_t\} E(y_{t+1} | S_{t+1} = j, I_t) \quad (2.3.1.6)$$

Para realizarmos a estimação das equações do MSM condicionamos o número de regimes a $N=2$, a defasagem da variável endógena e exógena para $p=1$ e solicitamos erros com heterocedasticidade e autocorrelação serial robustos, como nos modelos lineares. A previsão realizada é recursiva um passo a frente com a razão de $\frac{NP}{NR} = 0,4$.

2.4 Dados

Os dados utilizados nos modelos foram todas variáveis macroeconômicas tradicionais da

literatura, retiradas dos *websites* do Ipeadata¹⁵, do IBGE¹⁶, do Banco Central do Brasil¹⁷ e do *FRED*¹⁸ que tinham um longo período amostral, maiores que 20 anos, com a finalidade de conseguir atuar com o modelo de mudança de regime sob as variações estruturais, variações dos ciclos econômicos e outras variações que mudaram o comportamento dessas variáveis. Desse modo, aplicamos como variável endógena:

- A primeira diferença do logaritmo do retorno real da bolsa de valores de São Paulo (RSR), deflacionado pelo IGP;

e como variáveis exógenas:

- a primeira diferença do logaritmo dos preços das *Commodities* (COM);
- a primeira diferença do logaritmo do desemprego: antiga Pesquisa Mensal do Emprego - PME/ IBGE-¹⁹(DES);
- a primeira diferença do logaritmo do IGP (IGP);
- a primeira diferença do logaritmo do agregado monetário M1(M1);
- o logaritmo da taxa de juros *overnight* (OVER);
- a primeira diferença do logaritmo da produção física industrial dessazonalizada – PIM/IBGE – (PI);
- o hiato da produção industrial, construída através da produção industrial dessazonalizada menos a produção industrial potencial²⁰ (GAP);
- o *Relative Market Money Rate*, construída através da diferença da taxa de juros e a média móvel de 12 meses para trás (RMM);
- o logaritmo da taxa de juros dos EUA (EUA).

No anexo segue a Tabela A.2.3.1 com o período temporal da amostra e o teste de Dickey-

¹⁵ Disponível www.ipeadata.gov.br

¹⁶ Disponível www.ibge.gov.br

¹⁷ Disponível www.bc.gov.br

¹⁸ Disponível <http://research.stlouisfed.org/fred2/>

¹⁹ Utilizamos a PME/IBGE antiga por que a nova metodologia começou a ser feita em 2002. Por isso, optamos pela antiga com a finalidade de empregar uma grande amostra, de 1980 até 2002.

²⁰ Produção industrial potencial foi feita com o Filtro de Hodrick-Prescott.

Fuller aumentado²¹ para raiz unitária de cada variável empregada no estudo. Como podemos observar, todas as nossas variáveis estão aptas a serem regredidas de acordo como os modelos propostos nas subseções anteriores.

Além disso, quando os nossos modelos envolveram apenas uma variável exógena aplicamos o maior tamanho possível da amostra. No entanto, quando combinamos duas ou três variáveis macroeconômicas, utilizamos sempre o mesmo tamanho da amostra (janeiro de 1975 até agosto de 2008). Dessa forma, nós fizemos 44 combinações entre variáveis macroeconômicas de forma que não criássemos multicolinearidade entre as variáveis, tentando também atender alguma racionalidade econômica²².

Por fim, para realizarmos previsões três e seis meses à frente optamos por trimestralizar e semestralizar os dados. Em RWR (2005) o retorno mensal do índice da bolsa de valores era acumulado para esses horizontes. Por exemplo, se o modelo foi criado para prever seis meses à frente, a variável endógena na regressão tornava-se o acumulado de seis meses, e essa era regredida contra o retorno mensal defasado e a(s) variável(is) exógena(s). A vantagem desse método é que não se perde amostra. A desvantagem, é que quando nós colocamos esses dados no MSM, os algoritmos não conseguiram identificar os regimes. Desse modo, mesmo perdendo um número considerável de amostra, preferimos por trimestralizar e semestralizar os dados mensais.

3. RESULTADOS

Essa seção é destinada a identificar os tipos de modelos e as VM que apresentam melhores resultados de previsão. Para tanto, serão apresentados os resultados dos modelos lineares, na sessão 3.1; os resultados dos MSM,

²¹ O teste foi executado configurado com constante apenas, por entendermos que não faríamos modelos sem constante ou com tendência.

²² Nas estimações com duas ou três variáveis exógenas não incluímos a variável DES nem COM. A primeira por não possuir amostrar apenas até 2002, e a segunda por interferir na racionalidade econômica dos modelos.

na sessão 3.2; e os resultados globais na sessão 3.3. Além disso, serão apresentados, na seção 3.4, a robustez dos resultados encontrados. Por fim, na seção 3.5, construímos alguns resultados adicionais que vieram através da estimação dos modelos.

3.1 Restados dos modelos lineares

Essa subseção tem como objetivo apresentar os resultados das regressões lineares dentro e fora da amostra, começando pela subseção “Testes de Previsão Dentro da Amostra”, em que apresentaremos os coeficientes das regressões e os critérios de AIC e BIC. Posteriormente, já na subseção “Testes de Previsão Fora da Amostra”, faremos os testes fora da amostra que contemplam a Razão do RMSE (Erro Quadrático Médio de previsão) e do MAE (Erro Absoluto Médio de previsão), acompanhados dos testes de *encompassing* e MSE-F.

3.1.1 Testes de Previsão Dentro da Amostra

Os resultados dentro da amostra, feitos a partir da avaliação dos coeficientes estimados e dos critérios de informação, como podem ser observados na Tabela A.3.1, demonstraram que COM, para o horizonte mensal, GAP, para horizonte mensal e trimestral, e OVER, para o horizonte semestral, são variáveis que, através de modelos lineares, podem prever o RA. Observando apenas o coeficiente estimado, as variáveis COM, GAP, OVER, PI, M1, EUA e IGP tem os coeficientes consistentes em alguns dos modelos estimados ou em algum horizonte de previsão. Todavia, somente os modelos que usam COM, EUA, GAP e PI tiveram em 100% dos modelos estimados todos os coeficientes consistentes, em pelo menos um horizonte de previsão, sendo que as três primeiras variáveis apresentaram poder preditivo mensal e as duas últimas, trimestral. No horizonte semestral a variável OVER apresentou consistência, quando em 60% dos modelos teve seus coeficientes consistentes. Além disso, vale destacar que todos os modelos que continham a variável OVER e M1 tiveram ambos os parâmetros consistentes, mostrando poder preditivo desses modelos. Por

fim, as variáveis RMM e DES não tiveram coeficientes consistentes em nenhum dos modelos lineares estimados.

Agora, verificando os critérios de informação de Akaike (AIC) e Schwarz (BIC), temos a variável GAP em 100% dos modelos em que participou da estimação, conseguiu aumentar a quantidade de informação dos modelos. Além dessa, a VM OVER apresentou-se importante, principalmente, quando combinada com a variável IGP e M1²³ no horizonte semestral, onde conseguiu ser importante em 60% dos modelos estimados. Ainda, no mesmo horizonte de previsão, 40% dos modelos com a variável M1 seu critério de Akaike menor que os modelos restritos. Por fim, a variável COM e DES também adicionaram informação aos modelos nos horizontes mensais e semestrais, na primeira, e mensais e trimestrais na segunda.

Dessa forma, concluímos que nos testes dentro da amostra dos modelos lineares, a VM GAP mostrou-se sempre capacitada à prever o RA no horizonte mensal e trimestral, visto que gerou coeficientes extremamente significativos e adicionou informação nos critérios de AIC e BIC. A variável COM, que está presente em apenas três modelos, no horizonte mensal conseguiu adicionar informação aos critérios e teve seu coeficiente estimado consistente. Já a variável OVER mostrou capacidade preditiva dentro da amostra em 60% dos modelos de horizonte semestral, quando teve os coeficientes consistentes e os critérios de AIC e BIC ficaram menores. Além desse, destacamos a variável M1, quando combinada com a VM OVER, teve coeficientes consistentes e critérios de informação menor. Assim, podemos concluir que dentro da amostra temos evidências das VM GAP (nos horizontes mensal e trimestral), COM (no horizonte mensal), e OVER e M1 (no horizonte semestral), possuem poder preditivo sobre o RA.

3.1.2 Teste de Previsão Fora da Amostra

Os testes fora da amostra, compostos dos testes de *Encompassing*, MSE-F e das razões RMSE e MAE mostram que GAP, na previsão mensal e trimestral, e M1, na previsão semestral, são efetivamente as variáveis que trazem melhores previsões. Nos testes de *Encompassing* de D&M (1995), apontamos que os modelos com a variável GAP, no horizonte mensal e trimestral, não foram abarcados pelo modelo restrito em 14 dos 15 modelos. Já no horizonte semestral os modelos com as variáveis M1 e IGP, não foram abarcadas pelo modelo restrito em 16 de 20 modelos e 10 de 20 modelos, respectivamente. Contudo, avaliando através dos novos testes, C&M (2001), ENC-NEW e MSE-F, trouxeram resultado um pouco mais restritivos, em que permanecem os resultados dos modelos que contém as variáveis GAP e M1, mas os modelos com a variável IGP tem seus modelos abarcados pelo modelo restrito em quase todos. Dessa forma, optando por uma seleção mais rígida, entendemos que apenas as variáveis GAP e M1 podem prever o retorno fora da amostra. Quanto aos resultados das razões de RMSE e MAE, estão praticamente de acordo com os resultados apresentados pelos testes de *Encompassing*.

3.1.3 Resultados dos Modelos Lineares

Se o nosso trabalho tivesse apenas o intuito de reproduzir o artigo de RWR (2005) para dados brasileiros, os nossos resultados apenas indicariam que a variável GAP unanimemente é a variável macroeconômica mais capacitada de realizar previsão no horizonte mensal e trimestral, pois foi aprovada em todos os testes que a literatura aponta ser necessário para validar um modelo como detentor de um maior poder de previsão. Já no horizonte semestral, os modelos com a variável M1 tiveram sucesso apenas com os modelos que também continham OVER nos testes dentro da amostra e um surpreendente resultado fora da amostra, no qual 16 de 20 modelos com M1 não foram abarcados. Dessa forma, atribuímos que a variável M1 pode prever o IBOVESPA no horizonte semestral, mas condicionado aos modelos que envolvem taxa de juros. Por

²³ Todos os modelos com OVER e M1 mostraram se superiores que o modelo restrito nos critérios de informação.

entendermos ser necessário um alinhamento entre os testes dentro e fora da amostra.

Por fim, alertamos que resultados mensais e trimestrais, como vimos, mostram que os resultados dentro e fora da amostra estão alinhados. No entanto, os resultados semestrais não apresentaram tão boa performance em razão do reduzido tamanho da amostra. Esse problema pode se tornar mais significativo quando se usa a correção dos erros em Heterocedasticidade e Autocorrelação consistente (*HAC*), que podem distorcer mais em amostras menores.

3.2 Modelos de Markov–Switching

Os modelos de mudança de regime se mostraram, como mostra a Tabela A.3.2.1.1²⁴, com probabilidades de transição altas na maioria dos modelos, indicando regimes consistentes e persistentes. Todavia, os modelos de horizonte trimestral não conseguiram gerar sistematicamente modelos com regimes consistentes, sendo que dos 53 modelos estimados apenas 14 tiveram probabilidades consistentes e persistentes, enquanto que nos de horizonte mensal e semestral foram 50 e 33, respectivamente, do total de 53.

Avaliando o comportamento dos regimes podemos destacar, através das probabilidades filtradas, que a variável endógena foi a grande determinante desse regime, pois os comportamentos das probabilidades suavizadas foram muito semelhantes, mesmo alterando as variáveis exógenas²⁵. Segue em anexo um gráfico dessas probabilidades²⁶, a título de exemplo. Assim, identificamos um regime, considerado de baixa volatilidade, que se estende

²⁴ Tabela em anexo.

²⁵ Em alguns modelos que tiveram um bom desempenho na previsão dentro e fora da amostra, tiveram regimes um pouco diferentes, como o modelo GAP e IGP, que o regime de baixa é de 1976 a 1979, de 1995 a 1997 e 2002 a 2008.

²⁶ Em anexo segue o gráfico das probabilidades de transição suavizadas dos modelos que foram os mais acurados.

aproximadamente²⁷ de 1975 até 1982, de 1993 até 1998, e de 1998 até 2008. Já o outro regime, considerado de alta volatilidade, é mais provável de 1982 até 1993 e em 1998. Além disso, vale destacar que, embora não trocasse o regime, durante a década de 1990 e início da década 2000, todas as crises econômicas e financeiras elevaram as probabilidades filtradas de mudança de regime.

3.2.1 Testes de previsão dentro da amostra

Nos testes de previsão dentro da amostra de AIC e BIC, os modelos de MSM se mostraram sempre superiores aos modelos lineares, quando ambos de horizonte mensal. Já no horizonte trimestral apenas o critério de AIC ficou a favor dos MSM em 51 dos 53 modelos estimados, enquanto que o critério BIC ficou a favor dos modelos lineares em 29 dos 53. Todavia, levando em consideração que o critério de BIC é o que penaliza mais a adição de novos parâmetros e que os MSM possuem no mínimo o dobro de parâmetros mais dois, entendemos que esse critério não é suficiente para determinar se o modelo de mudança de regime é inferior aos modelos lineares de horizonte trimestral. Quanto aos MSM de horizonte semestral, não se apresentaram com melhores critérios de informação, sendo que apenas nove MSM foram melhores no critério de AIC que os modelos lineares.

Como apresentando na Tabela A.3.1, verificamos que as variáveis RMM e GAP apresentaram-se consistentes em ambos os regimes simultaneamente em mais de 70% dos modelos de horizonte mensal. Além disso, apareceram variáveis que se mostraram relevantes em prever o retorno em apenas um dos regimes, como OVER (em 73% dos modelos), no regime de alta volatilidade, e M1 (em 80% dos modelos), IGP (em 55% dos modelos) e EUA (em 85% dos modelos), no regime de baixa volatilidade. Já no horizonte semestral, apenas a VM RMM teve seus

²⁷ Em alguns modelos, devido à influência das variáveis macroeconômicas, esses regimes começaram e/ou terminaram um pouco antes ou um pouco depois das datas afirmadas acima.

parâmetros consistentes em ambos os regimes simultaneamente, pois embora a VM GAP tenha apresentando consistência em ambos os regimes, foram em poucos que isso ocorreu concomitantemente. Ainda para esse horizonte, a variável M1 também obteve parâmetros consistentes em ambos os regimes em 70% dos modelos estimados, apresentando capacidade preditiva.

Contudo, no horizonte trimestral, muito poucos modelos tiveram dois regimes consistentes e persistentes, fazendo com que nossa avaliação fosse condicionada a poucos modelos. Assim, a única variável que obteve sucesso foi a variável GAP, que em mais de 70% dos modelos para esse horizonte, teve dois regimes bem definidos. Enquanto isso, outras variáveis como EUA, RMM e IGP, nos poucos modelos que se apresentaram regimes bem definidos, tiveram consistência em seus parâmetros em ambos os regimes.

Entretanto, avaliando os critérios de informação AIC e BIC, observamos que nem todos os modelos conseguem ser efetivamente melhores que os modelos restritos, como seguem na Tabela A.3.1. Nos modelos de horizonte mensal e semestral respectivamente, apenas 14 e 17 modelos dos 53 dessas categorias foram superiores, enquanto que nos horizontes trimestrais foram 28. No entanto, vale ressaltar que esses critérios, principalmente o BIC, penalizam o número de parâmetros que sempre será, no mínimo, de dois a seis parâmetros a mais. Além disso, levando em consideração o argumento anterior, a maioria dos modelos mensais foi pior por menos de 1% em relação ao modelo restrito. Dessa forma, entendemos que não podemos dizer que esses modelos não-restritos não adicionaram mais informações. A máxima verossimilhança de quase todos os modelos é superior. Os modelos que se destacaram foram os modelos que envolviam COM e GAP, no horizonte mensal; GAP, RMM, M1, IGP, OVER e COM, no horizonte trimestral; e OVER, no horizonte semestral.

Sob essas duas avaliações, apontamos poder preditivo dentro da amostra nas variáveis GAP (no horizonte mensal e trimestral) e RMM (no horizonte trimestral). Além disso, devemos estar atentos ao desempenho de variáveis, como

M1, RMM e IGP, que tiveram bons desempenhos no horizonte mensal quando combinada com a variável GAP. Entretanto, pelo grande número de parâmetros estimados, combinado com coeficientes consistentes em apenas um regime, temos que os resultados obtidos com os coeficientes sejam indícios mais relevantes, mesmo sabendo que estamos usando erros sujeitos a técnica de Heterocedasticidade e Autocorrelação Consistentes (HAC).

3.2.2 Teste de Previsão fora da amostra

Os modelos de MSM superam os modelos lineares em 49 dos 53 modelos, quando o horizonte de previsão é mensal. Todavia, dos modelos trimestrais e semestrais, apenas 15 e oito, respectivamente, dos 53 modelos em cada categoria mostram-se mais capacitados. Esse pior desempenho dessas últimas categorias está diretamente relacionado à dificuldade dos MSM identificarem os regimes corretamente, como avaliamos, na seção de resultados gerais do MSM. Com isso, dado que a previsão no MSM é feita para cada regime e ponderada pela probabilidade de ocorrência de cada um, quando o modelo está com dificuldades de identificar os regimes, é provável de mais de um regime no modelo tenha dificultado mais, do que cooperado com a previsão.

Observando na Tabela A.3.2.3.2.1²⁸, as razões de RMSE e MAE dos MSM, encontramos evidências que a variável hiato do produto (GAP) possui muita informação sobre o do retorno no período $t + 1$. Os modelos de horizonte mensal que contém a variável macroeconômica GAP têm, aproximadamente, o RMSE e o MAE 2% e 4%, respectivamente, menores. Além disso, quando adicionamos aos modelos a variável IGP ganhamos até 1% na melhora de desempenho dos modelos. Quanto aos modelos de horizonte trimestral, podemos continuar afirmando que a variável GAP adiciona informação, pois a razão do RMSE e o MAE são menores em 8 dos 15 modelos estimados com essa variável. Além disso, verificamos que os modelos que trazem EUA e RMM também apresentam um bom desempenho,

²⁸ Tabelas em anexo.

ficando com o RMSE e MAE de 2% a 4% menores que do modelo restrito. Por fim, no horizonte semestral não tivemos indício que alguma variável pudesse prever o RSR.

3.2.4 Resultados dos MSM

Podemos concluir que os modelos de MSM são melhores para realizar previsões que os modelos lineares para retorno do IBOVESPA no horizonte mensal. Além disso, quando os MSM conseguiram fazer valer sua principal qualidade, estabelecer regimes bem definidos, os modelos de horizonte trimestral também tiveram mais sucesso. Ainda, as VM adicionaram informação aos modelos, com destaque para os modelos com GAP que, independentemente dos critérios adotados, sempre se mostraram melhores capacitados a prever o retorno da bolsa de valores brasileira nos horizontes mensais e trimestrais. Também destacamos que os modelos que combinavam o hiato do produto com IGP, aumentaram sua capacidade de previsão fora da amostra, indicando poder preditivo dessa variável. Além dessa, destacamos o bom desempenho dos dois modelos que continham as variáveis EUA e RMM, no horizonte trimestral, que se apresentaram capacitadas a preverem o retorno nos testes dentro e fora da amostra. Por fim, atribuímos ao desempenho não satisfatório nos testes fora da amostra, principalmente a variável EUA no horizonte trimestral, ao fato de a maioria dos modelos não possuíam um regime bem definido, ou seja, possuíam uma probabilidade de permanecer no mesmo regime baixa.

3.3 Resultados Gerais

Os resultados de todos nossos modelos indicam que o retorno do IBOVESPA possui dois regimes, sendo mais bem ajustado por um modelo não-linear de MSM, pois independente da variável macroeconômica adotada, esses tiveram mais sucesso nos testes dentro e fora da amostra que os modelos lineares. Além disso, verificamos que o GAP se ajustou muito bem aos modelos lineares e MSM, mostrando-se uma variável com muita informação sobre nossa variável endógena quando o objetivo é previsão nos horizontes mensais e trimestrais. Ainda, quando ajustado aos modelos de MSM com o

hiato do produto, a variável IGP também foi muito útil em melhorar a capacidade de previsão em relação ao modelo restrito. Também encontramos evidências que os MSM que contem EUA e RMM apresentam poder preditivo dentro e fora da amostra nas previsões trimestrais. Por fim, destacamos o bom desempenho dentro e fora da amostra dos modelos lineares de horizonte trimestral com a variável GAP e de horizonte semestral com a variável M1, quando acompanhada da variável OVER.

Contudo, as previsões tiveram mais sucesso no horizonte mensal, pois o sistema adotado para fazer previsão trimestral e semestral, através da semestralização e trimestralização dos dados, fez os modelos reduzirem o tamanho da amostra, dificultado a identificação dos regimes e estimação dos parâmetros pelo MSM. Além disso, o fato de estarmos usando erros com heterocedasticidade e Autocorrelação consistentes (HAC), pode desalinhar os resultados dentro e fora da amostra.

3.4 Resultados Robustos

Para verificar se a melhor capacidade de previsão do MSM advém das características do modelo ou da existência de uma possível quebra estrutural na série do retorno do IBOVESPA, decorrente da introdução do Plano Real na economia brasileira, estimamos modelos lineares com uma *dummy*, chamada de $Dummy_{1994}$, no período indicado pelo MSM. Como segue na equação abaixo

$$y_{t+1} = \alpha + \beta z_t + \gamma y_t + Dummy_{1994} + e_{t+1} \quad (3.4.1)$$

Dessa forma, observando os critérios de AIC e BIC, verificamos que o desempenho do MSM continua superior aos modelos de horizonte mensais e trimestrais. No horizonte semestral, o MSM, continua com poucos modelos melhores que os lineares. Todavia, vale destacar que os modelos lineares sem *dummy* possuem o desempenho semelhante ao modelo com *dummy*. Assim, os desempenhos se repetem, permanecendo todos os resultados já comentados acima em favor do MSM. Já os testes fora da

amostra, confirmam que o RMSE e MAE dos modelos MSM foram inferiores, com destaque para o desempenho dos modelos de horizonte mensal.

3.5 Resultados Adicionais

Essa seção tem o objetivo de avaliar os resultados que surgiram através da estimação dos modelos, mas que não tratam especificamente da capacidade de previsão dos mesmos. Na sessão 3.5.1 apresentaremos os resultados que são relevantes à discussão de inflação e retorno real. Já as sessões 3.5.2 a 3.5.5 serão confrontados nossos resultados com a literatura, em relação às variáveis OVER, PI, RMM e EUA.

3.5.1. Inflação Vs. Retorno Real

Avaliando a relação entre RSR e inflação, verificamos que nos modelos lineares essas duas variáveis não possuem relação. Todavia, quando as inserimos nos modelos de mudança de regime, observamos uma forte relação em ambos os regimes, porém com comportamentos antagônicos. No regime de alta volatilidade, quando o Brasil convivia com a inflação elevada, os agentes tendem a aumentar o retorno real quando a inflação aumentava no período anterior. Já no regime de baixa volatilidade, a inflação funciona exatamente ao contrário: na medida em que aumenta a inflação no período $t-1$, o mercado reduz seu retorno no período t . Dessa forma, evidenciamos que a relação negativa entre essas duas variáveis somente é verdadeira no regime de baixa volatilidade.

Além disso, se observarmos a variável M1, podemos avaliar, que no MSM apresenta consistência e uma relação positiva no período de baixa volatilidade. Indicando que o mercado, ao ver a base monetária aumentar, passa a aumentar o retorno no período posterior. Ainda, levando em consideração que GAP do produto é uma variável importantíssima para o RSR e sempre negativamente relacionada, entendemos que o mercado ao ver que há redução (aumento) da base monetária supõe restrição (expansão) da política monetária, o que aumenta (reduz) o hiato do produto – GAP –, que por sua vez, atinge as expectativas sobre o futuro da economia,

reduzindo (aumentando) o retorno real no período seguinte. Assim, acreditamos que a relação negativa entre inflação e o retorno real no período de baixa volatilidade está de acordo com a política monetária vigente no Brasil, visto que o grande alvo era a inflação. Na medida em que os dados de inflação eram divulgados, os agentes refaziam suas projeções inflacionárias, o que condicionava o aperto (afrouxamento) da política monetária, impactando negativamente (positivamente) sobre o retorno de ações, como descrevemos acima.

A principal consequência desse resultado é a semelhança em termos de resultado com os encontrados por Fama, na economia dos EUA; Nunes, Costa Jr e Meurer, para economia brasileira; e outros autores, porém tentando evidenciar outro motivo para essa relação. Assim, indicando que no caso brasileiro haveria um novo comportamento vinculado a políticas monetárias altamente restritivas a inflação. Esse estudo abre precedente para investigarmos se existe os *efeitos monetários* em outros países que possuem metas de inflação. Nossa avaliação não tem capacidade de identificar relações de causalidade, por isso, tenhamos que criar um modelo que tem essa capacidade, como um VAR ou um MS-VAR, para tratar esse questionamento de forma mais apropriada. Todavia, temos que estar atentos que, para esse sistema funcionar, é necessário que a inflação passada seja um forte determinante da expectativa de inflação, pois caso isso não ocorra, a política monetária não se moverá conforme a inflação passada, não tendo efeitos sobre o RA.

3.5.2 Taxa de juros nominal

A taxa de juros nominal, OVER, teve os coeficientes consistentes apenas no regime de alta volatilidade, quando apresentou coeficientes negativos. Entretanto, no regime de metas de inflação, inserido em 1999 na economia brasileira, que tem como metodologia sinalizar ao mercado os movimentos do banco central com antecedência, quando há mudanças na taxa, normalmente, o mercado já precificou os ativos. Como esse período de metas de inflação é predominante no regime de baixa volatilidade, é natural que não encontremos, nesse regime, relação entre RA e OVER.

3.5.3 Produção industrial

Na maioria dos nossos modelos a produção industrial não apresentou ser uma variável que influenciasse o retorno acionário na frequência mensal. Todavia, no horizonte trimestral em modelos lineares, essa variável apresentou-se consistente, indo de encontro com a lógica verificada no GAP do produto, que melhoras na economia geram aumento no retorno. Esse resultado está de acordo com Caselani e Eid (2008), para economia brasileira, e Chen (2008), para a economia estadunidense, que também encontram a relação negativa. Todavia, RWR (2005) encontram para o Canadá e Alemanha, também no horizonte trimestral, uma relação positiva para as variáveis. Dessa forma, os resultados devem ser mais bem investigados, visto que nossos estudos não conseguem explicar o motivo desse resultado, mesmo que seja bastante pontual e essa variável não melhora a capacidade de previsão dos modelos.

3.5.4 RMM (*Relative Money Market Rate*)

A variável RMM, presente no estudo de RWR (2005), mostrou-se importante nos MSM, embora no modelo linear não ajudasse na previsão dentro ou fora da amostra. Seu coeficiente ficou negativo na maioria dos modelos mensais, ainda que tenha variado, assumindo no regime de baixa volatilidade um valor normalmente maior que no regime de alta volatilidade. Esse resultado está de acordo com RWR (2005), segundo os quais RMM foi importante nas economias dinamarquesa, estadunidense, holandesa, japonesa e sueca.

3.5.5 Taxa de juros dos Estados Unidos

A variável EUA mostrou-se consistente apenas no regime de baixa volatilidade, apontando que a partir da década de 90 o Ibovespa passou a ser mais fortemente atingido pelas variações na taxa de juros dos EUA. Além disso, essa variável apresentou-se consistente apenas nos horizontes mensais, com coeficiente negativo, ou seja, uma elevação da taxa de juros estadunidense causa fuga de recursos da bolsa de valores brasileira, para outras aplicações naquele

país. Esse resultado está de acordo com Abugri (2008), e parcialmente contrário ao resultado de Caselani e Eid (2008), que nem sempre encontra influência do mercado dos EUA no mercado nacional.

4. CONCLUSÃO

O nosso trabalho teve o objetivo de testar se as variáveis macroeconômicas podiam prever o retorno real do índice da bolsa de valores de São Paulo (IBOVESPA). A literatura sobre o assunto mostra que algumas variáveis podem melhorar a previsão em alguns períodos da história, sendo que conforme o país as VM que ajudavam na previsão se modificavam. No caso brasileiro, poucos trabalhos tinham o objetivo de testar essa capacidade, embora muitos desejavam descobrir os impactos das VM sobre o retorno. Todavia, os resultados encontrados eram contraditórios, com a significância das variáveis alternando de um trabalho para outro. Além disso, ignoravam completamente as mudanças institucionais da economia brasileira, que podiam influenciar o comportamento da principal bolsa de valores do Brasil e das VM. Dessa forma, regredimos contra o retorno do IBOVESPA as variáveis: Commodities, Desemprego, Inflação, Agregado Monetário, Taxa de Juros, Produção Industrial, Hiato do Produto, e Taxa de juros dos EUA. Isto teve a finalidade de encontrar quais dessas que podiam adicionar informações aos modelos de previsão lineares, como o tradicional na literatura; e aos modelos de mudança de regime markoviana, com o objetivo de captar as mudanças estruturais e temporárias das variáveis macroeconômicas e do RA.

A metodologia empregada tinha o objetivo de ser completa, tentando verificar de diversas formas, dentro e fora da amostra, se as variáveis realmente poderiam ajudar na previsão dos modelos. Dentro da amostra, verificamos a consistência dos parâmetros e os critérios de informação AIC e BIC. Já fora da amostra, comparamos se as previsões recursivas um passo a frente realizadas com modelos com VM eram melhores que os modelos sem essas variáveis. Para testar isso, utilizamos as razões do RMSE e MAE para verificar quais modelos erravam menos na previsão; além dos testes de

Encompassing, de D&M (1995), C&M (2001), e MSE-F, de McCracken (2007), com os valores assintóticos ajustados de C&M (2001, 2004), verificando se os modelos eram abarcados pelos modelos sem as variáveis macroeconômicas.

Os nossos resultados indicaram que o retorno do IBOVESPA possui dois regimes, um de regime de baixa volatilidade, de 1975 até 1982, de 1993 até 1998 e de 1998 até 2008, e o outro, de alta volatilidade, de 1982 até 1993, verificados através do melhor ajuste e melhor previsão fora da mostra dos MSM em relação aos modelos lineares. Assim, embora a variável hiato do produto (GAP) já tenha se mostrado capacitada a prever o retorno real do IBOVESPA nos modelos lineares, o seu melhor desempenho apareceu nos MSM, no qual foi aprovado em todos os testes propostos no horizonte mensal e trimestral. Além dessa, a VM IGP também apresentou capacidade preditiva quando combinada com a variável GAP no horizonte mensal. Ainda, os modelos trimestrais com a variável EUA e RMM reduziram significativamente as razões de RMSE e MAE e tiveram parâmetros consistentes, também confirmando capacidade preditiva. Por fim, os modelos de previsão lineares semestrais que contém a variável M1, acompanhada da variável OVER, se destacaram com poder preditivo dentro e fora da amostra.

Contudo, os modelos de MSM tiveram um desempenho amplamente superior aos modelos lineares apenas no horizonte mensal, sendo que nos horizontes trimestral e semestral esse teve dificuldades de identificar os regimes. Nós atribuímos a essa dificuldade ao reduzindo número de amostras nesses horizontes, o que dificultou esses modelos se mostrarem superiores aos lineares. Dessa forma, os modelos lineares, sob essas circunstâncias se mostraram em geral superiores, com destaque para os modelos semestrais com variáveis macroeconômicas (M1 acompanhada de OVER), que foram aprovados em todos os testes. Embora na maioria os trimestrais fossem melhores, os modelos com a variável GAP e os modelos com EUA e RMM, superaram os modelos lineares.

Como teste de robustez, propusemos mostrar que a melhor capacidade preditiva do MSM não vinha de uma suposta quebra

estrutural no período pós-plano real, e criamos modelos lineares com uma variável *Dummy* no período indicado pelo MSM. O resultado apontou uma grande superioridade do MSM novamente, mostrando que, embora haja uma mudança estrutural no período do Plano Real, o seu maior sucesso advém do fato que o MSM faz uma previsão baseada em dois regimes ponderados pela probabilidade de ocorrência de cada desses. Dessa forma, sempre que houve períodos de elevação na volatilidade, o MSM captou um novo regime através da probabilidade de transição, possibilitando fazer melhores previsões, enquanto que o modelo linear errou sistematicamente durante esses períodos.

Adicionalmente, mas não vinculado com nosso principal objetivo, acabamos testando quais os impactos que as variáveis macroeconômicas podem efetuar sobre o retorno do IBOVESPA. Assim, na relação entre inflação e retorno, verificamos que no regime de baixa volatilidade a inflação é negativamente relacionada com o retorno, como encontrado na literatura. Todavia, a variável M1, no mesmo regime, é positivamente relacionada, indicando que ao reduzir (aumentar) a base monetária, o governo está indicando se a política monetária será restritiva (expansiva), fazendo o retorno das ações aumentarem (caírem) no período seguinte, por causa da melhoria (ou piora) na expectativa da atividade economia. Ainda, reforçando nosso argumento, o comportamento da variável GAP é uma prova que os aumentos (reduções) no hiato do produto, causam reduções (aumentos) no retorno no período seguinte, mostrando que há influência da atividade econômica sobre o retorno. Dessa forma, indicamos que no regime de baixa volatilidade, os agentes, ao verificarem a inflação subir (descer), condicionam a expectativa de inflação sobre os períodos seguintes, o que influencia a escolha da política monetária restritiva (expansiva), que acaba influenciando a atividade econômica, que por sua vez, reduz (aumenta) o retorno no período seguinte.

A taxa de juros, que seria o melhor medidor da política monetária, não apresentou efeitos significativos, por que no período de metas de inflação, o Banco Central brasileiro, seguindo a metodologia, sempre sinalizando,

com antecedência, quais seriam seus movimentos, fazendo com que no período anterior, possivelmente o mercado já havia precificado conforme o novo arranjo monetário. Ainda, RMM e EUA, mostraram-se consistentes e negativamente relacionadas ao retorno, sendo que a segunda VM, apenas apresentou-se consistente no regime de baixa volatilidade, indicando que o a taxa de juros dos EUA passou a influenciar o mercado sistematicamente a partir dos anos 90.

Assim, nosso trabalho pode contribuir com a literatura em identificar algumas VM que podem ajudar a prever o retorno da bolsa de valores do Brasil, empregando modelos de previsão com mudança de regime markoviana, que se mostraram mais adequados pela grande oscilação e instabilidade da economia brasileira. Dessa forma, nos próximos trabalhos que tentarem utilizar capacidade de previsão em horizontes mensais do retorno, deixamos a indicação de usar variáveis macroeconômicas e

modelos com mudança de regime markoviano. Nesse sentido, abre-se a possibilidade de criar modelos de previsões com MSM adicionando modelagem da variância, MSM-GARCH (SWARCH), que permitiria não apenas uma correção dos erros, mas uma modelagem mais acurada, ajudando, por exemplo, na utilização dessa metodologia para *Value-at-Risk*. Além disso, o trabalho abre precedentes para novas pesquisas que venham a testar qual é a relação de causalidade entre GAP, M1, IGP, OVER e o retorno, para verificar a existência do que chamamos de *efeitos monetários*. Ainda, devemos buscar desenvolver testes de *Encompassing*, incluindo os valores assintóticos para os MSM, testando de forma mais precisa a previsão desses modelos no futuro. Por fim, sugerimos aplicar essa metodologia em outras economias emergentes, e verificar se as VM locais podem prever o retorno com o MSM, como evidenciamos na economia brasileira.

REFERÊNCIA BIBLIOGRÁFICA

- ABUGRI, B.A. Empirical relationship between macroeconomic volatility and stock returns: Evidence from Latin American markets. **International Review of Financial Analysis**, v. 17, n. 2, p. 396-410, 2008.
- ADRANGI, B., CHATRATH, A., & SANVICENTE, A. Z.. Inflation, Output, and Stock Prices: Evidence from Brazil. São Paulo: IBMEC, 2000. (FINANCELAB WORKING PAPER, 16)
- ASPREM, M.. Stock prices, asset portfolios and macroeconomic variables in ten European countries. **Journal of Banking & Finance**, v. 13, n. 4-5, 1989.
- BALVERS, R.J., COSIMANO, T.F. & MCDONALD, B. Predicting stock returns in an efficient market. **Journal of Finance**, . 45, n. 4, p. 1109–1128, 1990.
- BESSEC, M.; BOUABDALLAH, O. What Causes The Forecasting Failure of Markov-Switching Models? A Monte Carlo Study. **Studies in Nonlinear Dynamics & Econometrics**, Berkeley Electronic Press, v. 9, n.2, p. 1171-1171, 2005.
- BODIE, Z. Common stocks as a hedge against inflation. **Journal of Finance**, v. 31, n.2, p. 459–470, 1976.
- BOYD, J., HU, J., JAGANNATHAN, R.. The Stock Market's Reaction to Unemployment News: Why Bad News Is Usually Good for Stocks. **The Journal of Finance**, v. 60, n. 2, 2005.
- BREEN, W., GLOSTEN, L. R. & JAGANNATHAN, R.. Economic Significance of Predictable Variations in Stock Index Returns. **Journal of Finance**, v. 44, n. 5, 1989.
- CASELANI, C. N. ; EID Jr., W.. Fatores Microeconômicos e Conjunturais e a Volatilidade dos Retornos das Principais Ações Negociadas no Brasil. **RAC Eletrônica (Online)**, v. 2, p. 10, 2008.
- CHAN, L. K., KARCESKI, J., & LAKONISHOK, J.. **The Risk and Return from Factors**.

- Cambridge: National Bureau of Economic Research, 1997. (Working Paper n. 6098)
- CHEN, N.F. Financial investment opportunities and the macroeconomy. **Journal of Finance**, v. 46, n. 2, p. 529–554, 1991.
- CHEN, S.S. Predicting the bear stock market: Macroeconomic variables as leading indicators. **Journal of Banking and Finance**, v. 33, n. 2, p. 211–223, 2009.
- CLARK, T.E. & MCCRACKEN, M.W. Tests of equal forecast accuracy and encompassing for nested models. **Journal of Econometrics**, v. 105, n. 1, p. 85–110, 2001.
- CLARK, T.E. & MCCRACKEN, M.W. **Forecast-based model selection in the presence of structural breaks**. Kansas City : Federal Reserve Bank of Kansas City, 2002. (Research Working Paper RWP 02-05)
- CLARK, T.E. & MCCRACKEN, M.W. **Improving Forecast Accuracy by Combining Recursive and Rolling Forecast**. Kansas City : Federal Reserve Bank of Kansas City, 2004.
- CLARK T. E & WEST K. D. **Aproximate Normal Test For Equal Predictive Accuracy In Nested Models**. National Bureau Of Economic Research, 2006 (Technical Working Paper 326).
- CONOVER, C. M., JENSEN, G. R. & JOHNSON, R. R (1999). Monetary environments and international stock returns. **Journal of Banking & Finance**, v. 23, n. 9, 1999.
- DE. MEDEIROS, O. R. ; RAMOS, F. C. . Determinantes do Desempenho e Volatilidade na Bovespa: Um Estudo Empírico. Congresso USP de Controladoria e Contabilidade. **Anais**. São Paulo, 2004
- DIEBOLD, F. & MARIANO, R. Comparing predictive accuracy. **Journal of Business and Economic Statistics**, v. 13, p. 253-65, 1995.
- FAMA, E. F. Stock returns, real activity, inflation, and money. **The American Economic Review**, v. 71, n. 4, 1981.
- FAMA, E. F. & SCHWERT, G. William. Asset Returns and Inflation. **Journal of Financial Economics**, v. 5, n. 2, 1977.
- FASOLO, A. M. ; PORTUGAL, M. S. . Imperfect Rationality and Inflationary Inertia: A new estimation of the Phillips Curve for Brazil. *Estudos Econômicos*. Instituto de Pesquisas Econômicas, São Paulo, v. 34, p. 725-776, 2004.
- FLANNERY, M.J. & PROTOPAPADAKIS, A.A. Macroeconomic factors do influence aggregate stock returns. **The Review of Financial Studies**, v. 15, n. 3, 2002.
- GAY, R.D. Effect Of Macroeconomic Variables On Stock Market Returns For Four Emerging Economies: Brazil, Russia, India, And China. **International Business and Economics Research Journal**, v. 7, n. 1, 2008.
- GESKE, R. & ROLL, R. The fiscal and monetary linkage between stock returns and inflation. **Journal of Finance**, v. 38, n. 1, 1983.
- GOETZMANN, W. N. & JORION, P.. Testing the Predictive Power of Dividend Yields. **The Journal of Finance**, v. 48, n. 2, 1993.
- GUNASEKARAGE, A. Macroeconomic Influence on the Stock Market: Evidence from an Emerging Market in South Asia. **Journal of Emerging Market Finance**, v. 3, n. 3, 2004.
- HAMILTON, J. D. A new approach to the economic analysis of nonstationary time series and the business cycle. **Econometrica**, v. 7, n. 2, 1989.
- HAMILTON, J. D.. **Time Series Analysis**. Princeton: Princeton University Press, 1994.
- HARVEY, D. I., LEYBOURNE, S. J. & NEWBOLD, P. Tests for Forecast Encompassing. **Journal of Business & Economic Statistics**, v. 16, n. 2, 1998.

- JAGANNATHAN, R., KUBOTA, K. & TAKEHARA, Hitoshi. Relationship between Labor-Income Risk and Average Return: Empirical Evidence from the Japanese Stock Market. **Journal of Business**, v. 71, n. 3, 1998.
- JAGANNATHAN, Ravi & WANG, Zhenyu. **The CAPM is alive and well**. Minneapolis: Federal Reserve Bank of Minneapolis, 1993 (Staff Report n. 165).
- JAMES, C., KOREISHA, S., PARTCH, M.. A VARMA Analysis of the Causal Relations Among Stock Returns, Real Output, and Nominal Interest Rates. **The Journal of Finance**, v. 40, n. 5, 1985.
- JAFFE, J.F. & MANDELKER, G. The "Fisher Effect" for Risky Assets: An Empirical Investigation. **Journal of Finance**, v. 31, n.2, 1976.
- KIRBY, C.. Measuring the Predictable Variation in Stock and Bond Returns. **The Review of Financial Studies**, v. 10, n. 3, 1997.
- LINTNER, J. Inflation and security returns. **Journal of Finance**, v. 30, n. 2, 1975.
- MCCRACKEN, M.W. Asynptotic for out of sample test of Granger Causality. **Journal of Econometric**. v. 140, 2007.
- NELSON, C.R. Inflation and rates of return on common stocks. **Journal of Finance**, v. 31, n. 2, 1976.
- NELSON, C.R. & KIM, M. J.. Predictable Stock Returns: The Role of Small Sample Bias. **The Journal of Finance**, v. 48, n. 2, 1993.
- NEWKEY, Whitney & WEST, Kenneth. A Simple Positive Semi-Definite, Heteroskedasticity and Autocorrelation Consistent Covariance Matrix. **Econometrica**, v. 55, n. 3, 1987.
- NUNES, M.S, COSTA JR, N.C.A, & MEURER, R. A relação entre o mercado de ações e as variáveis macroeconômicas: uma análise econométrica para o Brasil. **Rev. Bras. Econ.**, Dez 2005, vol.59, no.4, p.585-607. ISSN 0034-7140
- OUDET, B.A. The Variation of the Returns on Stock in Periods of Inflation. **Journal of Financial and Quantitative Analysis**, v. 8, p. 247-258, 1973.
- PEARCE, D. K. & ROLEY, V. V.. **Stock Prices and Economic News**. Cambridge: National Bureal of Economic Research, 1984. (Working Paper n. 1296)
- PESARAN, M.H. & TIMMERMANN, A. Predictability of stock returns: Robustness and economic significance. **Journal of Finance**, v. 50, n. 4, 1995.
- RAPACH, David E., WOHAR, Mark E. & RANGVID, Jesper. Macro variables and international stock return predictability. **International Journal of Forecasting**, v. 21, n. 1, 2005.
- REILLY, F. K., JONSON, G. L. e SMITH, R. E.. Individual Common Stocks as Inflation Hedges. **The Journal of Financial and Quantitative Analysis**, v. 6, n. 3, 1971.
- TERRA, P. R. S.. Inflação e retorno do mercado acionário em países desenvolvidos e emergentes. **Revista de Administração Contemporânea**, v. 10, n. 3, 2006

ANEXO

Gráfico A.3.2.1.1 – Probabilidades de Transição Suavizadas do modelo compostos de RMM GAP EUA com horizonte mensal

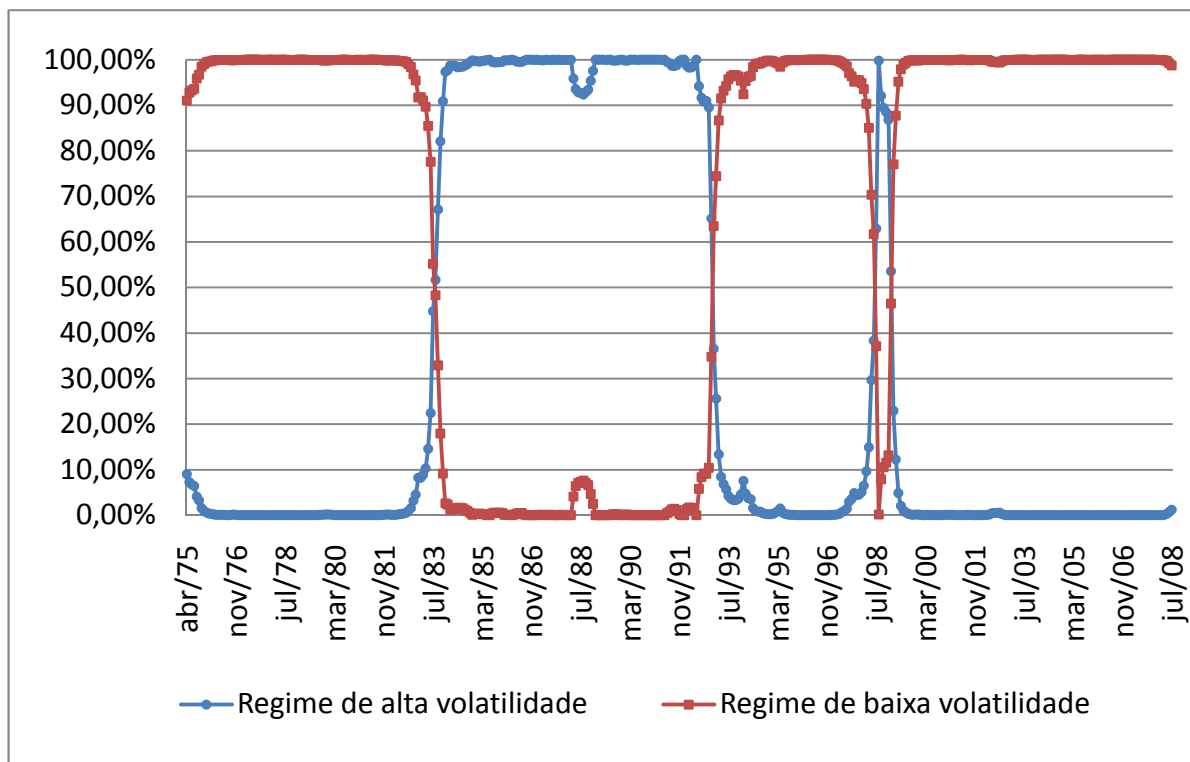


Tabela A.1 - Valores Assintóticos Dos Testes de encompassing e MSE-F

		Número de parâmetros adicionais do modelo não restrito (K)				
Percentil de Significância		1	2	3	4	5
ENC-T	0.9	1.005	1.086	1.105	1.192	1.17
	0.95	1.338	1.445	1.529	1.552	1.544
	0.99	1.997	2.073	2.203	2.273	2.245
ENC-NEW	0.9	0.685	1.019	1.285	1.528	1.639
	0.95	1.079	1.481	1.865	2.181	2.349
	0.99	2.098	2.604	3.098	3.462	3.651
MSE-F	0.9	0.814	1.029	1.117	1.313	1.228
	0.95	1.298	1.733	2.062	2.246	2.235
	0.99	2.768	3.426	4.08	4.541	4.466

Tabela A.2.3.1 - Período Amostral e Teste de Estacionariedade

Variável	Período	PV do teste ADF
COM	Mar de 1980 até ago de 2008	0.0000
RSR	Mar de 1980 até ago de 2008	0.0000
DES	Jan de 1980 até dez de 2002	0.0351
RSR	Jan de 1980 até dez de 2002	0.0000
PI	Fev de 1975 até ago de 2008	0.0000
GAP	Fev de 1975 até ago de 2008	0.0000
RSR	Fev de 1975 até ago de 2008	0.0000
IGP	Abr de 1978 até ago de 2008	0.0000
RSR	Abr de 1978 até ago de 2008	0.0000
M1	Fev de 1970 até ago de 2008	0.0000
RSR	Fev de 1970 até ago de 2008	0.0000
OVER	Fev de 1974 até ago de 2008	0.0000
RSR	Fev de 1974 até ago de 2008	0.0000
RMM	Dez de 1974 até ago de 2008	0.0000
RSR	Dez de 1974 até ago de 2008	0.0000
EUA	Abr de 1968 até ago de 2008	0.0000
RSR	Abr de 1968 até ago de 2008	0.0000
RSR	Jan de 1975 até ago de 2008	0.0000
RMM	Jan de 1975 até ago de 2008	0.0000
GAP	Jan de 1975 até ago de 2008	0.0000
PI	Jan de 1975 até ago de 2008	0.0000
EUA	Jan de 1975 até ago de 2008	0.0000
M1	Jan de 1975 até ago de 2008	0.0000
IGP	Jan de 1975 até ago de 2008	0.0008
OVER	Jan de 1975 até ago de 2008	0.0000

Tabela A.3.1.1 - Valor percentual da razão do número de modelos não-restritos que superaram o modelo restrito sobre o total de modelos estimados

Variável	Horizonte de previsão	Coeficientes		Razão AIC		
		Modelos Lineares	MSM	Modelos Lineares	MSM	
			Regime de Alta Volatilidade	Regime de Baixa Volatilidade		
GAP	Mensal	100%	100%	73%	100%	67%
	Trimestral	100%	67%	93%	100%	60%
	Semestral	7%	67%	60%	20%	20%
PI	Mensal	0/15	33%	0/15	0/15	7%
	Trimestral	100%	87%	87%	7%	40%
	Semestral	7%	33%	0/15	13%	20%

EUA	Mensal	100%	30%	85%	45%	15%
	Trimestral	0/20	45%	80%	25%	55%
	Semestral	0/20	10%	30%	15%	25%
COM	Mensal	100%	0/1	0/1	100%	100%
	Trimestral	0/1	0/1	0/1	0/1	100%
	Semestral	0/1	100%	100%	100%	100%
OVER	Mensal	0/15	73%	7%	40%	7%
	Trimestral	0/15	47%	47%	27%	60%
	Semestral	60%	60%	53%	60%	67%
M1	Mensal	15%	45%	80%	40%	35%
	Trimestral	0/20	40%	55%	25%	65%
	Semestral	20%	70%	75%	30%	40%
IGP	Mensal	0/20	30%	55%	25%	20%
	Trimestral	0/20	65%	55%	25%	60%
	Semestral	20%	45%	40%	30%	25%
DES	Mensal	0/1	0/1	0/1	100%	100%
	Trimestral	0/1	100%	100%	100%	0/1
	Semestral	0/1	100%	100%	0/1	100%
RMM	Mensal	0/20	90%	75%	30%	40%
	Trimestral	0/20	100%	100%	40%	40%
	Semestral	0/20	75%	90%	20%	20%

Tabela A.4.1.2.1 - Teste de Previsão fora da amostra dos modelos lineares

Modelo	Mensal			Trimestrais			Semestrais		
	ENT-T=	ENC-NEW	MSE-F	ENT-T=	ENC-NEW	MSE-F	ENT-T=	ENC-NEW	MSE-F
RMM e GAP	1.9653	6.8512	2.3796	2.1469	4.3533	0.311	0.2628	0.0753	-0.486
RMM e PI	-1.7148	-1.1233	-2.662	-0.5384	-0.5891	-3.0665	1.5991	0.7011	0.1389
RMM e EUA	-0.3069	-0.6056	-6.8824	-0.0145	-0.0044	-0.3988	0.3999	0.1704	-0.6919
RMM e M1	-0.6791	-0.7738	-2.8687	-1.8649	-0.3746	-0.8524	3.3576	1.5832	1.8732
RMM e IGP	-0.9256	-0.3713	-0.8886	-1.6312	-0.8236	-2.263	2.3266	0.8608	0.7208
OVER e GAP	1.8855	6.5852	1.5288	1.9935	3.4912	-0.5403	-1.3846	-0.6845	-3.2016
OVER e PI	-0.6957	-0.6581	-2.3191	-1.2152	-1.2691	-5.1431	-0.4013	-0.2543	-3.1488
OVER e EUA	-0.3985	-0.8138	-7.7004	-1.102	-0.7077	-2.7935	-0.9036	-0.5401	-3.5008
OVER e M1	-0.6677	-0.6603	-2.3489	-0.9334	-0.8057	-4.0189	2.2523	1.4138	-1.7262
OVER e IGP	-0.2123	-0.2025	-1.4474	-0.8336	-0.8241	-4.6899	1.0261	0.779	-7.1467
GAP e EUA	1.5457	6.046	-4.2079	1.7578	2.8542	-2.9224	-1.8633	-0.359	-1.013
GAP e M1	1.9165	6.4873	1.6889	2.1122	4.4027	0.2008	2.2261	0.8128	1.0246
GAP e IGP	1.9627	7.0611	2.2225	2.0854	4.0133	0.1197	1.2168	0.3412	0.265
PI e EUA	-0.7065	-1.351	-8.1077	-0.3665	-0.4169	-2.9465	0.3989	0.1882	-0.8222
PI e M1	-1.5168	-1.3369	-3.6813	-0.6975	-0.6944	-2.9467	3.0663	1.6158	1.8075
PI e IGP	-1.266	-0.8993	-2.2287	-0.9487	-0.9008	-3.3597	2.1408	0.956	0.6555

EUA e M1	-0.5607	-1.0959	-8.0424	-0.7946	-0.2122	-0.8004	1.8273	1.0989	0.4779
EUA e IGP	-0.2509	-0.4882	-6.3375	-1.4377	-0.4269	-1.2224	1.0538	0.5661	-0.4487
M1 e IGP	-0.2141	-0.2603	-2.0796	-1.5227	-0.547	-1.4776	3.9995	1.7469	2.7192
RMM GAP EUA	1.5029	5.817	-4.5278	1.7263	2.8097	-3.2557	-1.655	-0.3324	-0.962
RMM GAP M1	1.8757	6.1172	1.4875	2.086	4.3249	0.0873	2.3745	0.8755	1.094
RMM GAP IGP	1.9054	6.53	1.9749	2.0299	3.6755	-0.3625	1.1465	0.3104	0.218
RMM PI EUA	-0.7622	-1.5222	-8.99	-0.4081	-0.4913	-3.3396	0.5943	0.308	-0.9228
RMM PI M1	-1.4712	-1.5837	-4.6458	-0.7649	-0.8129	-3.4391	2.9766	1.7863	1.5079
RMM PI IGP	-2.0344	-1.3986	-3.3141	-1.1777	-1.1939	-4.4115	1.9906	0.9258	0.3595
RMM EUA M1	-0.6056	-1.2656	-9.2393	-1.1182	-0.2957	-0.9541	1.8184	1.0865	0.3026
RMM EUA IGP	-0.4696	-0.9184	-7.6377	-1.8317	-0.6732	-1.7891	0.8931	0.4445	-0.5921
RMM M1 IGP	-0.5258	-0.5781	-2.4214	-1.5241	-0.8222	-2.6009	5.0407	2.0981	3.443
GAP EUA M1	1.4801	5.5336	-4.7005	1.8135	3.0995	-3.1288	0.9521	0.4362	-0.1996
GAP EUA IGP	1.5335	6.0587	-4.3407	1.7427	2.8631	-2.9699	0.0287	0.0111	-0.8269
GAP EUA OVER	1.4582	5.6154	-4.942	1.6353	2.5659	-3.2745	-2.2198	-0.9793	-3.6562
GAP M1 IGP	1.9313	6.4761	1.6459	2.1296	4.0744	-0.6395	2.4841	0.8931	1.2476
GAP M1 OVER	1.8468	6.2241	1.2053	2.0924	3.6475	-1.142	1.7056	0.8798	-2.435
GAP IGP OVER	1.8717	6.6178	1.4419	1.999	3.42	-0.9559	0.6305	0.3966	-7.3296
PI EUA M1	-0.8831	-1.6862	-9.2884	-0.4977	-0.5524	-3.0917	1.7984	1.1465	0.3262
PI EUA IGP	-0.6604	-1.3079	-8.2013	-0.6782	-0.7112	-3.2613	0.9884	0.5511	-0.6305
PI EUA OVER	-0.5183	-1.0615	-8.2701	-0.9607	-1.0208	-4.3621	-0.9532	-0.5766	3.6389
PI M1 IGP	-0.8251	-0.9702	-3.6183	-0.9397	-0.875	-3.4662	3.6978	1.8897	2.7124
PI M1 OVER	-0.6957	-0.6581	-2.3191	-1.0564	-1.1384	-5.548	2.1481	1.3838	-1.7464
PI IGP OVER	-0.5752	-0.6008	-2.3979	-0.9453	-1.1447	-6.3654	0.7366	0.5247	-7.6726
EUA M1 IGP	-0.371	-0.7999	-8.2114	-1.2207	-0.392	-1.2377	2.163	1.2337	1.1304
EUA M1 OVER	-0.5761	-1.1568	-8.3982	-0.9025	-0.6155	-3.0091	1.7397	1.0345	-2.1921
EUA IGP OVER	-0.3554	-0.7457	-7.7762	-0.7652	-0.6237	-3.6041	0.7554	0.5593	-7.2904
M1 IGP OVER	-0.323	-0.3945	-2.3139	-0.8694	-0.8323	-4.558	0.6299	0.4927	-8.4385
COM	1.9883	9.5444	-9.0836	2.235	1.0963	0.6935	0.1876	0.111	-3.5367
IGP	-0.0052	-0.1325	-0.3543	2.0684	1.1227	1.6487	2.7685	2.2122	3.4274
M1	-0.0015	-0.1903	-1.0658	3.2126	1.7274	2.7715	2.9989	2.9897	4.3486
OVER	-0.0123	-0.6743	-2.7065	1.004	0.9627	-0.3541	2.5342	2.1264	0.8344
PI	-0.0046	-0.9598	-2.2218	-0.0986	-0.1085	-2.2401	2.5755	1.9829	1.7519
GAP	0.043	7.0307	2.2899	2.3651	4.986	0.7156	2.7382	3.7877	1.713
RMM	-0.0002	-0.0419	-0.089	2.7284	0.4893	0.8239	3.1729	1.3727	2.0425
EUA	-0.0172	-0.369	-2.6587	0.6689	0.5465	-0.658	2.1101	2.2723	2.0065
DES	0.2606	0.056	-0.0043	-2.4882	-2.2796	-7.9342	2.9272	1.5828	1.5724

Tabela A.3.2.1.1 - Probabilidade de Transição dos modelos MSM

Horizonte de previsão	Mensal		Trimestral		Semestral	
Modelo	P11	P22	P11	P22	P11	P22
COM	0.978093	0.988343	-1.2E-23	0.967856	0.680655	0.661133
DES	0.985252	0.993973	0.408061	0.854123	0.684592	0.178297
IGP	0.9647	0.965676	0.180594	0.982198	0.921484	0.96445
M1	0.971058	0.98959	-2.9E-17	0.976762	0.94396	0.971344

OVER	0.99127	0.974871	0.873884	7.9E-18	0.946686	0.969062
PI	0.978819	0.99115	0.987319	0.971076	0.969026	0.937693
GAP	0.983132	4.99E-17	0.970057	0.987133	0.670096	0.398222
RMM	0.979393	0.99127	0.941531	0.877007	0.944741	0.96675
EUA	0.972353	0.990859	0.221069	0.219932	0.693878	0.327881
RMM e GAP	0.97768	0.98375	0.943323	0.851552	0.947572	0.965998
RMM e PI	0.97899	0.991187	0.445505	0.763624	0.948836	0.967879
RMM e EUA	0.978888	0.991151	0.315364	0.890432	0.949794	0.965614
RMM e M1	0.984158	0.978675	0.165761	0.819518	0.952413	0.487165
RMM e IGP	0.981431	0.974142	0.904757	0.235864	0.949315	0.96519
OVER e GAP	0.986099	-2.00E-20	0.969236	0.986978	0.946282	0.97013
OVER e PI	0.979067	0.991202	0.869336	-1.6E-21	0.08356	1.33E-17
OVER e EUA	0.979058	0.991179	0.667754	0.701742	0.742175	-3.7E-21
OVER e M1	0.991464	0.979429	1.08E-17	0.991972	0.912866	0.423938
OVER e IGP	0.979034	0.991294	-3.6E-22	0.968592	0.938637	0.359497
GAP e EUA	0.978195	6.94E-17	0.650045	0.666042	0.676223	0.760185
GAP e M1	0.991602	0.97994	0.968777	0.987189	0.950879	0.964058
GAP e IGP	0.991547	0.979736	6.1E-17	0.845996	0.946169	0.964986
PI e EUA	0.978883	0.991165	0.951486	-2.8E-21	0.946598	0.96787
PI e M1	0.979216	0.991403	0.819641	2.58E-17	0.675457	0.584288
PI e IGP	0.978864	0.991261	0.962887	0.908952	0.943666	0.968082
EUA e M1	0.979266	0.991411	-4.5E-23	0.967279	0.690308	0.59485
EUA e IGP	0.978848	0.991241	0.942029	0.8346	0.946789	0.964891
M1 IGP	0.991442	0.979259	-7.8E-23	0.96745	0.610389	0.24382
RMM, GAP e EUA	0.979786	0.99146	0.892113	0.690216	0.94656	0.96555
RMM, GAP e M1	0.977975	0.983586	0.907594	0.004451	0.953599	0.963183
RMM, GAP e IGP	0.970019	0.980275	0.941097	0.187162	0.948373	0.964772
RMM, PI e EUA	0.978951	0.991148	0.409214	0.975642	0.596546	0.428772
RMM, PI e M1	0.983484	0.978662	-1.2E-20	0.785471	0.942659	0.872985
RMM, PI e IGP	0.981743	0.974447	0.310102	0.6744	0.947433	0.96816
RMM, EUA e M1	0.38044	0.943743	0.816321	0.519656	0.890295	0.387897
RMM, EUA e IGP	0.982835	0.975102	0.515779	0.928346	0.950029	0.965076
RMM, M1 e IGP	0.983705	0.978144	0.445538	0.923495	0.959075	0.872985
GAP, EUA e M1	0.991631	0.980073	4.08E-20	0.715612	0.818357	0.328041
GAP, EUA e IGP	0.991518	0.979927	2.52E-18	0.836576	0.944737	0.964523
GAP, EUA e OVER	0.983394	6.00E-20	0.788238	0.548476	0.944873	0.969348
GAP, M1 e IGP	0.954109	0.97709	0.968728	0.987135	0.956123	0.967157
GAP, M1 e OVER	0.99165	0.980179	0.968585	0.987048	0.662796	0.465203
GAP, IGP e OVER	0.831766	1.37E-17	-1.4E-21	0.818082	0.928195	0.309465
PI, EUA e M1	0.991416	0.979287	0.881431	3.73E-21	0.696305	0.60519
PI, EUA e IGP	0.978926	0.991258	0.869723	8.26E-17	0.943359	0.967951
PI, EUA e OVER	0.979076	0.991192	0.971497	0.421513	0.949305	0.970325
PI, M1 e IGP	0.979271	0.991448	0.960383	0.904837	0.954152	0.969776
PI M1 OVER	0.991477	0.979463	0.960383	0.904837	0.908129	0.438693
PI, IGP e OVER	0.979115	0.991315	0.788332	2.39E-17	0.931674	0.468131
EUA, M1 e IGP	0.991436	0.979309	-0.00012	0.972176	0.814204	0.330296
EUA, M1 e OVER	0.991473	0.979497	-4.2E-19	0.980436	0.888839	0.229057

EUA, IGP e OVER	0.979021	0.991271	0.969285	0.37237	0.846954	-1.1E-21
M1, IGP e OVER	0.979458	0.991501	6.23E-05	0.976381	0.911645	0.273546

Tabela A.3.2.3.2.1 - Teste de Previsão Fora da Amostra dos MSM - Razão de RMSE e MAE

Modelo	Mensal		Trimestral		Semestral	
	RMSE	MAE	RMSE	MAE	RMSE	MAE
RMM e GAP	0.9746	0.9551	0.9605	0.9134	1.0935	1.0634
RMM e PI	1.0147	1.0154	1.0217	1.0014	1.0895	1.0811
RMM e EUA	1.0204	1.0125	0.9715	0.9871	1.1341	1.1745
RMM e M1	1.0309	1.0440	1.0394	1.0357	1.0963	1.0896
RMM e IGP	1.0126	1.0055	1.0550	1.0487	1.0788	1.0939
OVER e GAP	0.9851	0.9616	1.0014	0.9776	1.2819	1.1629
OVER e PI	1.0146	1.0169	1.1104	1.0752	1.2604	1.1728
OVER e EUA	1.0227	1.0183	1.0285	1.0372	1.1380	1.0285
OVER e M1	1.0038	1.0090	1.1239	1.1569	1.2461	1.1556
OVER e IGP	0.9961	0.9971	1.0797	1.0211	1.3033	1.2139
GAP e EUA	1.1981	1.1751	1.0135	0.9688	1.1305	1.0587
GAP e M1	0.9830	0.9672	0.9586	0.9059	1.1879	1.1454
GAP e IGP	0.9789	0.9624	0.9922	0.9220	1.0929	1.0511
PI e EUA	1.0262	1.0232	1.0165	1.0003	1.2861	1.2443
PI e M1	1.0268	1.0295	1.0490	0.9933	1.0512	1.0654
PI e IGP	1.0009	1.0030	1.0710	1.0144	1.1381	1.1321
EUA e M1	1.0247	1.0243	1.0783	1.0404	1.2073	1.1612
EUA e IGP	1.0091	1.0086	1.0015	1.0078	1.1099	1.1008
M1 IGP	1.0179	1.0171	1.0312	1.0519	1.0374	1.0693
RMM, GAP e EUA	0.9917	0.9618	1.0002	0.9788	1.1661	1.1343
RMM, GAP e M1	1.0013	0.9904	0.9955	0.9851	1.1105	1.1332
RMM, GAP e IGP	0.9701	0.9617	0.9896	0.9940	1.1694	1.1617
RMM, PI e EUA	1.0295	1.0190	1.0173	0.9955	1.1673	1.2001
RMM, PI e M1	1.0571	1.0606	1.0581	1.0331	1.1470	1.1813
RMM, PI e IGP	1.0343	1.0282	1.1104	1.0646	1.1442	1.1453
RMM, EUA e M1	1.0534	1.0473	1.0075	1.0123	1.1667	1.1697
RMM, EUA e IGP	1.0340	1.0407	0.9774	0.9624	1.1151	1.0953
RMM, M1 e IGP	1.0202	1.0258	1.0572	1.0387	0.9792	0.9456
GAP, EUA e M1	0.9909	0.9716	1.0447	1.0056	1.2177	1.2022
GAP, EUA e IGP	1.0016	0.9891	1.0538	0.9766	1.1927	1.2161
GAP, EUA e OVER	1.0294	1.0039	1.0400	0.9961	1.3341	1.2431
GAP, M1 e IGP	0.9942	0.9714	0.9862	0.9465	1.0934	1.0779
GAP, M1 e OVER	1.0175	0.9991	0.9941	0.9586	1.1099	1.0486
GAP, IGP e OVER	0.9721	0.9465	1.0211	1.0404	1.3824	1.2911
PI, EUA e M1	1.0495	1.0510	1.0558	1.0480	1.2032	1.1528
PI, EUA e IGP	1.0171	1.0172	1.0825	1.0918	1.3026	1.2564
PI, EUA e OVER	1.0312	1.0274	1.0942	1.0880	1.3758	1.2656

PI, M1 e IGP	1.0149	1.0193	1.0478	1.0003	1.0868	1.0614
PI M1 OVER	1.0140	1.0183	1.1060	1.0491	1.1580	1.1251
PI, IGP e OVER	1.0067	1.0088	1.1407	1.0969	1.5538	1.4332
EUA, M1 e IGP	1.0203	1.0072	1.0594	1.0568	1.1181	1.1220
EUA, M1 e OVER	1.0363	1.0525	1.0378	1.0880	1.3817	1.2697
EUA, IGP e OVER	1.0148	1.0127	1.0113	1.0335	1.4053	1.3027
M1, IGP e OVER	1.0049	1.0128	1.1298	1.1350	1.3747	1.3694
COM	0.9933	0.9617	1.0739	1.0861	1.2636	1.2317
DES	1.0157	1.0009	1.1031	1.1253	1.3053	1.3035
IGP	0.9943	0.9936	1.0296	1.0432	1.0524	1.0789
M1	1.0037	1.0084	0.9950	0.9897	1.1313	1.1035
OVER	1.0181	1.0207	1.0174	0.9795	1.0669	1.0570
PI	1.0102	1.0114	1.0842	1.0490	1.0984	0.9601
GAP	0.9816	0.9643	0.9442	0.9215	0.9908	0.9179
RMM	0.9949	0.9944	1.0181	1.0307	0.9505	0.9588
EUA	1.0064	1.0045	1.0913	1.1629	1.0201	1.0455

Tabela A.3.2.3.2.2 - Testes Fora da Amostra do MSM

Modelo	Mensal			Trimestral			Semestral		
	ENC-NEW	ENC-T	MSE-F	ENC-NEW	ENC-T	MSE-F	ENC-NEW	ENC-T	MSE-F
RMM e GAP	7.4483	2.3431	6.4745	6.3614	1.5700	3.1902	-0.8531	-0.9347	-3.1536
RMM e PI	-1.4444	-1.8163	-3.3462	0.9240	0.3700	-1.5893	-1.1494	-1.9445	-3.1497
RMM e EUA	0.3092	0.1338	-4.5962	2.4215	1.6877	2.2688	-1.0488	-1.2345	-4.1956
RMM e M1	-0.5831	-0.2488	-6.8580	-0.4921	-0.3429	-2.8211	-0.5267	-0.5676	-3.3145
RMM e IGP	0.0087	0.0050	-2.8692	-0.8855	-0.5533	-3.8660	-0.8885	-1.6706	-2.7195
OVER e GAP	6.4545	1.9350	3.5216	5.0527	1.3856	-0.1093	-1.8915	-1.0493	-7.3701
OVER e PI	-1.3090	-1.5099	-3.3395	-0.3626	-0.1622	-7.1742	-1.7535	-0.9527	-6.9303
OVER e EUA	-1.0484	-0.5570	-5.0787	0.0578	0.0363	-2.0789	0.3435	0.1736	-4.1693
OVER e M1	0.5523	0.3946	-0.9040	-1.0900	-0.5869	-7.9177	0.1547	0.0819	-6.9740
OVER e IGP	1.1754	0.8210	0.8971	-0.8535	-0.3988	-5.4074	1.1371	0.5817	-7.8075
GAP e EUA	7.6210	1.4081	-35.2044	4.3577	1.2250	-1.0027	-0.6201	-0.5277	-4.2297
GAP e M1	6.1289	1.9411	4.0018	5.4798	1.3147	3.3529	-1.2852	-0.9461	-5.5366
GAP e IGP	8.3327	2.1472	5.0624	5.8283	1.5211	0.6027	-0.9268	-0.8649	-3.1574
PI e EUA	-1.6714	-1.0421	-5.8662	0.3726	0.2597	-1.2265	-2.2995	-2.1260	-7.5593
PI e M1	-1.6363	-0.9887	-6.0151	-0.3102	-0.1413	-3.4709	-0.2386	-0.2132	-1.8345
PI e IGP	0.4334	0.3397	-0.2139	-0.2587	-0.1142	-4.8749	-1.5773	-2.0375	-4.4781
EUA e M1	-0.0852	-0.0381	-5.5271	-1.4406	-0.7489	-5.3133	-0.7315	-0.5169	-5.9263
EUA e IGP	0.4686	0.2558	-2.0788	0.8781	0.5524	-0.1219	-0.9322	-0.9151	-3.5971
M1 IGP	-0.7985	-0.5045	-4.0337	0.1292	0.0696	-2.2603	0.6299	0.5230	-1.2023
RMM, GAP e EUA	7.3351	1.8916	1.9270	4.0147	1.2919	-0.0126	-1.7408	-2.1077	-5.0431
RMM, GAP e M1	3.6916	1.3309	-0.3071	3.2534	1.0139	0.3466	-0.2814	-0.2419	-3.6350
RMM, GAP e IGP	8.8703	2.4851	7.2443	3.2414	1.1181	0.8068	-1.5254	-1.4865	-5.1485
RMM, PI e EUA	-0.3237	-0.1357	-6.5267	3.0060	0.7165	-1.2794	-1.7389	-1.7781	-5.0900
RMM, PI e M1	-3.2654	-1.6055	-12.1960	-0.6682	-0.3215	-4.0622	-0.6528	-0.4713	-4.7681

RMM, PI e IGP	-1.8114	-0.9378	-7.5874	-0.7608	-0.3110	-7.1769	-1.5395	-1.7703	-4.6587
RMM, EUA e M1	-1.2021	-0.4287	-11.4789	1.4490	0.8122	-0.5592	-1.6065	-1.6026	-5.1801
RMM, EUA e IGP	-1.1014	-0.5136	-7.5241	-1.5552	-0.7170	-8.0375	-1.2575	-1.4985	-3.7203
RMM, M1 e IGP	0.0543	0.0234	-4.5269	-1.0830	-0.7118	-4.0047	1.1050	0.6422	-0.1204
GAP, EUA e M1	6.3894	1.7649	2.1157	5.4391	1.4405	-3.1841	-1.6189	-1.4979	-6.0634
GAP, EUA e IGP	10.3838	2.2099	-0.4167	3.9674	1.0885	-3.7770	-1.2515	-1.2132	-5.6761
GAP, EUA e OVER	5.1667	1.3558	-6.5529	3.4067	1.0160	-2.8632	-1.6154	-0.8684	-8.2691
GAP, M1 e IGP	6.2948	1.7441	1.3826	6.3690	1.5385	1.0665	0.0602	0.0429	-2.9373
GAP, M1 e OVER	4.1419	1.1120	-39992	4.8436	1.4054	0.4529	1.4023	0.6373	-3.5577
GAP, IGP e OVER	8.9410	2.2396	6.7288	5.3666	1.5765	-15456	-0.4851	-0.2342	-9.1880
PI, EUA e M1	-2.6096	-1.2373	-10.6939	-0.9090	-0.4998	-3.9091	-1.4209	-1.0900	-5.8401
PI, EUA e IGP	-0.2186	-0.1112	-3.8861	-0.5512	-0.2526	-5.5752	-2.2429	-1.8599	-7.8648
PI, EUA e OVER	-1.8996	-1.0047	-6.9421	-0.5319	-0.2116	-6.2576	-1.7425	-0.8440	-8.9452
PI, M1 e IGP	0.0163	0.0093	-3.3855	0.3272	0.1482	-3.3879	-0.4035	-0.3703	-2.7760
PI M1 OVER	-0.4031	-0.2858	-3.2072	-0.5143	-0.1993	-6.9258	1.6115	0.9720	-4.9601
PI, IGP e OVER	0.0866	0.0577	-1.5814	-1.0313	-0.4137	-8.7939	-0.3328	-0.1749	-11.0446
EUA, M1 e IGP	0.7008	0.3298	-4.5583	0.9104	0.4147	-4.1348	-0.2293	-0.1597	-3.8081
EUA, M1 e OVER	0.2829	0.1095	-8.0080	1.3961	0.9171	-2.6973	-0.1042	-0.0475	-9.3434
EUA, IGP e OVER	0.3892	0.1713	-3.3780	1.7217	0.6814	-0.8390	-0.0640	-0.0370	-9.3515
M1, IGP e OVER	1.0831	0.5698	-1.1723	-0.8294	-0.3918	-8.2218	0.9260	0.5519	-8.9753
COM	3.5334	1.5210	1.3066	-0.5842	-0.5185	-4.3919	-0.7465	-0.5802	-5.9759
DES	1.4333	0.9490	-2.4285	-1.1592	-0.7811	-4.8172	-1.4779	-1.0200	-5.7817
IGP	1.2397	1.1339	1.5962	-0.9753	-13137	-2.6176	-0.7646	-1.1256	-2.2318
M1	0.2583	0.1866	-1.0042	0.6884	0.8047	0.4374	-1.6017	-0.8897	-4.8101
OVER	-1.4116	-0.9461	-4.2119	0.1374	0.0710	-1.3466	0.5816	0.3909	-2.4299
PI	-0.9972	-1.6283	-2.3300	-0.9753	-0.4310	-5.6795	1.3932	0.6763	-2.5882
GAP	7.4209	2.0630	4.4182	5.1048	1.7741	4.6350	3.1106	11534	0.9458
RMM	0.6773	1.3574	1.1554	-0.0858	-0.0949	-1.3643	1.2229	11906	2.1315
EUA	-0.1491	-0.0853	-1.7637	0.4105	0.1671	-7.3878	-0.2873	-10900	-0.8982