



PROJEÇÃO DAS RECEITAS CORRENTES DO ESTADO DO RIO DE JANEIRO: APLICAÇÕES DE MODELOS UNIVARIADOS E MULTIVARIADOS

*ELCYON CAIADO ROCHA LIMA**, *LÉO DA ROCHA FERREIRA*** E
*VICTOR HUGO M. B. HONAIER****

Resumo: Este artigo desenvolve modelos univariados e multivariados para as principais variáveis de receita do Estado do Rio de Janeiro. Para todas as variáveis, chegamos a modelos com razoável habilidade preditiva. Para algumas variáveis, as previsões dos modelos multivariados superaram as dos modelos univariados, o que é, em geral, um resultado difícil de obter.

Palavras-chaves: Univariado Estrutural. BVAR. BVEC. SARIMA.

Códigos JEL: C32, C52, C51.

Current taxes forecasts for the State of Rio de Janeiro: applications of univariate and multivariate models

Abstract: This article specifies and estimates univariate and multivariate models for the main revenue variables followed by the Rio de Janeiro State Treasury Office. For all variables, we develop models which have a good out-of-sample forecasting ability. For some variables, the out-of-sample forecasts of multivariate models over perform those of univariate models, a result which is difficult to obtain.

Key-words: Univariate Structural Models. BVAR. BVEC. SARIMA.

JEL Code: C32, C52, C51.

Nota: Este trabalho contou com o apoio financeiro da Secretaria da Fazenda do Estado do Rio de Janeiro.

* Professor Associado da Faculdade de Ciências Econômicas da Universidade do Estado do Rio de Janeiro; pesquisador do IPEA.

** Professor Titular e Diretor do Centro de Ciências Sociais da Universidade do Estado do Rio de Janeiro.

*** Pesquisador de informações estatísticas e geográficas de contas nacionais no Instituto Brasileiro de Geografia e Estatística (IBGE).

1 INTRODUÇÃO

O orçamento anual do estado do Rio de Janeiro atingiu, nos últimos anos, um valor de aproximadamente 60 bilhões de reais. Neste artigo foram desenvolvidos modelos de previsão univariados e multivariados para as principais receitas do estado. O desenvolvimento de bons modelos de previsão para as receitas do estado pode ser útil aos formuladores da política fiscal estadual ao incrementar a habilidade de se prever o comportamento das receitas do estado no curto, médio e longo prazos.

Com esta introdução, o artigo contém cinco seções. Na seção 2 fazemos uma revisão da literatura; na seção 3 a metodologia dos modelos univariado e multivariado é desenvolvida; na seção 4 apresentamos os resultados empíricos dos modelos; enquanto na seção 5, concluímos.

2 REVISÃO DE LITERATURA

Neste artigo os modelos pertencentes às seguintes classes: SARIMA (Seasonal Autoregressive Integrated Moving Average Model), modelos univariados estruturais, modelo BVAR (Bayesian Vector Autoregression Model) e BVEC (Bayesian Vector Error Correction Model) são estimados.

Uma revisão da literatura sobre a capacidade preditiva de diferentes modelos de séries temporais pode ser encontrada em Gooijer e Hyndman (2006). Esta seção do artigo contém um sumário das principais considerações realizadas por Gooijer e Hyndman.

A utilização de modelos SARIMA, mesmo quando identificados automaticamente por algum software (um exemplo seria o DEMETRA) tem permitido previsões um passo à frente e para séries temporais tão acuradas quanto às obtidas por profissionais experientes (ver Texter & Ord, 1989 e Harvey & Todd, 1983).

Os modelos univariados estruturais têm sido amplamente utilizados em previsões de séries temporais. Para uma comparação com os modelos SARIMA ver Harvey & Todd, 1983.

Os modelos BVAR utilizam distribuições a priori para os parâmetros que refletem a crença de que muitas variáveis econômicas se comportam como um passeio aleatório (Litterman, 1986). Esta classe de modelos tem sido amplamente utilizada em previsões de variáveis macroeconômicas com bom desempenho preditivo. Kling and Bessler (1985), comparam a capacidade preditiva fora-da-amostra de diversos modelos multivariados, inclusive modelos BVAR, em previsões mais longas (ver Wang & Bessler, 2004).

3 METODOLOGIA

A seguir, descreveremos a metodologia dos modelos univariados e multivariados utilizados na elaboração das previsões.

3.1 MODELOS UNIVARIADOS

3.1.1 MODELOS ARIMA E SARIMA

Uma coleção de dados, distribuídos no tempo e observados sequencialmente, é denominada uma série temporal. Essas observações, em geral, apresentam correlação serial. A sequência de observações $X_1, X_2, X_3, \dots, X_t$, é uma série temporal de tamanho t , onde t indica o último instante com dado disponível. Dada uma série temporal, $X_{1:t} = (X_1, X_2, X_3, \dots, X_t)$, com t observações temporais da variável aleatória X , procura-se obter um bom candidato para o processo estocástico gerador da série.

O modelo ARIMA (Autoregressive Integrated Moving Average), desenvolvido por Box e Jenkins, Box et al. (1994), permite chegar a um candidato para o processo gerador da série temporal $X_{1:t}$ que satisfaz às seguintes propriedades: depende de observações passadas, X_{t-1}, \dots, X_{t-p} , e depende dos erros de previsão um passo à frente de X , e_{t-1}, \dots, e_{t-q} , onde $e_t = X_t - X_t^p$ e X_t^p é a previsão de X utilizando informações amostrais até o período $t-1$. As observações amostrais da série temporal são um subconjunto de uma realização particular do processo estocástico gerador da série.

O modelo ARMA possui os seguintes componentes: um componente autorregressivo e um componente média móvel.

Um processo autorregressivo de ordem p , $AR(p)$, é definido por:

$$X_t = \rho_1 X_{t-1} + \rho_2 X_{t-2} + \dots + \rho_p X_{t-p} + \varepsilon_t$$

Onde ε_t é uma variável aleatória com esperança condicional igual a zero e não correlacionada serialmente (ruído branco); ρ_1, \dots, ρ_p são parâmetros.

Um processo médias móveis de ordem q , MA(q), é definido por:

$$X_t = \varepsilon_t - \alpha_1 \varepsilon_{t-1} - \dots - \alpha_q \varepsilon_{t-q}$$

Onde $\alpha_1, \dots, \alpha_q$ são parâmetros e ε_t já foi definido anteriormente.

Um processo ARMA(p, q) é um modelo misto, que inclui estes dois componentes:

$$X_t - \rho_1 X_{t-1} - \dots - \rho_p X_{t-p} = \varepsilon_t - \alpha_1 \varepsilon_{t-1} - \dots - \alpha_q \varepsilon_{t-q}$$

O modelo pode ser descrito utilizando o operador de defasagens L , que é definido por:

$$L^d X_t = X_{t-d}$$

O modelo ARMA(p, q) pode ser então descrito, utilizando o operador de defasagens L , por:

$$(1 - \rho_1 L - \dots - \rho_p L^p) X_t = (1 - \alpha_1 L - \dots - \alpha_q L^q) \varepsilon_t$$

O processo X_t pode ser estacionário ou não-estacionário. Os parâmetros do modelo acima podem ser restritos para que o processo seja estacionário. Quando determinado processo é não estacionário e é diferença - estacionário ele é denominado um processo integrado.

Defina $\Delta = 1 - L$ (L é o operador de defasagens). Um processo X_t é integrado de ordem “ d ” se

$$\Delta^d X_t = (1 - L)^d X_t \text{ é estacionário.}$$

Um modelo ARIMA(p, d, q) para determinada série de tempo X_t é um modelo no qual X_t é integrável de ordem d . A série estacionária $(1 - L)^d X_t$ é então modelada por um processo ARMA(p, q), e o modelo então toma a seguinte forma:

$$(1 - \rho_1 L - \dots - \rho_p L^p)(1 - L)^d X_t = (1 - \alpha_1 L - \dots - \alpha_q L^q) \varepsilon_t$$

Observando-se esta última equação pode-se concluir que o modelo ARIMA(p, d, q) é uma generalização de todos os modelos apresentados anteriormente: o modelo autorregressivo e o modelo médias móveis para variáveis com diferentes ordens de integração.

O modelo ARIMA-Sazonal, denominado SARIMA, é denotado por ARIMA(P, D, Q)_s, onde P é a ordem do componente autorregressivo sazonal, D é a ordem das diferenças sazonais e Q é a ordem da média móvel sazonal:

$$(1 - \beta_1 L^S - \dots - \beta_p L^{Sp})(1 - L^S)^D x_t = (1 - \phi_1 L^S - \dots - \phi_q L^{Sq}) \varepsilon_t$$

Devido às propriedades das séries de tempo, que apresentam tendência, sazonalidade e movimentos cíclicos, é desejável se combinar o modelo ARIMA tradicional com o SARIMA puro, obtendo-se então o modelo ARIMA(p, d, q) x ARIMA(P, D, Q)_s que é dado por:

$$\begin{aligned} (1 - \rho_1 L - \dots - \rho_p L^p)(1 - \beta_1 L^S - \dots - \beta_p L^{Sp})(1 - L)^d (1 - L^S)^D X_t = \\ = (1 - \alpha_1 L - \dots - \alpha_q L^q)(1 - \phi_1 L^S - \dots - \phi_q L^{Sq}) \varepsilon_t \end{aligned}$$

As séries de tempo utilizadas neste estudo, além de apresentarem não estacionaridade (tendência), sazonalidade e ciclos, também mostraram alguns problemas como a presença de observações discrepantes (*outliers*) e mudanças no nível das séries. Houve, portanto, a necessidade de se adotar um modelo mais genérico do que o modelo ARIMA (p, d, q) x ARIMA(P, D, Q)s.

Foi adotado, então, o modelo que será descrito a seguir.

Seja $Z_{1:t} = (z_1, z_2, \dots, z_t)$ a série de tempo de interesse. Foi então ajustada a seguinte regressão:

$$z_t = y_t \beta + x_t$$

Onde: y_t é um vetor com variáveis *dummies* para lidar com a presença de observações discrepantes e mudanças de nível; β é um vetor de parâmetros estimados e x_t é modelado como um processo ARIMA (p, d, q) x ARIMA(P, D, Q)s.

3.1.2 MODELO UNIVARIADO ESTRUTURAL

O termo estrutural é utilizado para indicar uma especificação selecionada de maneira a identificar os componentes de interesse: tendência, sazonal e irregular. Da mesma forma que, em um modelo econométrico convencional, determinada equação possui certa especificação para que possa ser identificada (i.e., uma equação de demanda por determinado produto).

Como os modelos econométricos convencionais, os modelos univariados utilizados podem ser apresentados na forma estrutural e na forma reduzida. Alguns modelos são identificáveis e outros não. Neste artigo não há nenhuma discussão sobre identificação e só apresentamos e estimamos modelos identificáveis. Descrevemos a seguir, separadamente, as especificações utilizadas para identificar cada componente não observável da série de tempo (tendência e sazonal) e mostramos que a forma reduzida dos modelos adotados, desconsiderando-se a existência de sazonalidade, tem uma representação ARIMA. Para uma descrição mais detalhada desta classe de modelos ver Harvey e Todd(1983).

Tendência

Na maior parte da literatura até a década dos 70 a tendência era o componente da série que se alterava lentamente ao longo do tempo. A ideia era que ao observar a tendência fosse possível obter alguns movimentos de longo prazo da série ao longo da amostra. Este não é o ponto de vista adotado aqui. Na abordagem modelo-orientada (*model-based*), que tem dominado a literatura mais recentemente, o interesse maior pela tendência decorre da possibilidade de extrapolá-la no futuro. Portanto, a tendência é definida com base nas suas propriedades de predição.

Considerando-se o que foi abordado anteriormente, a tendência é definida como aquele componente da série, para o qual o seu valor dessazonalizado tende, à medida em que aumenta o horizonte de previsão. Ou seja, de acordo com a definição de tendência, a previsão de longo prazo da série dessazonalizada é igual à sua tendência.

Neste artigo foram utilizadas duas especificações alternativas da tendência: sem taxa de crescimento (sem inclinação) e com taxa de crescimento (com inclinação). Apresentamos a seguir as duas especificações alternativas para a tendência.

Com Taxa de Crescimento (Inclinação)

Neste caso a tendência é uma função linear do tempo e é válida apenas localmente (tendência

local). O nível (μ_t) e a taxa de crescimento (β_t) evoluem segundo as equações abaixo:

$$\mu_t = \mu_{t-1} + \beta_{t-1} + \eta_t, \quad \eta_t \sim N(0, \sigma_\eta^2)$$

$$\beta_t = \beta_{t-1} + \xi_t, \quad \xi_t \sim N(0, \sigma_\xi^2)$$

A relação entre a tendência e os valores dessazonalizados da variável de interesse (y_t) é dada pela seguinte equação:

$$y_t = \mu_t + \varepsilon_t, \quad \varepsilon_t \sim N(0, \sigma_\varepsilon^2)$$

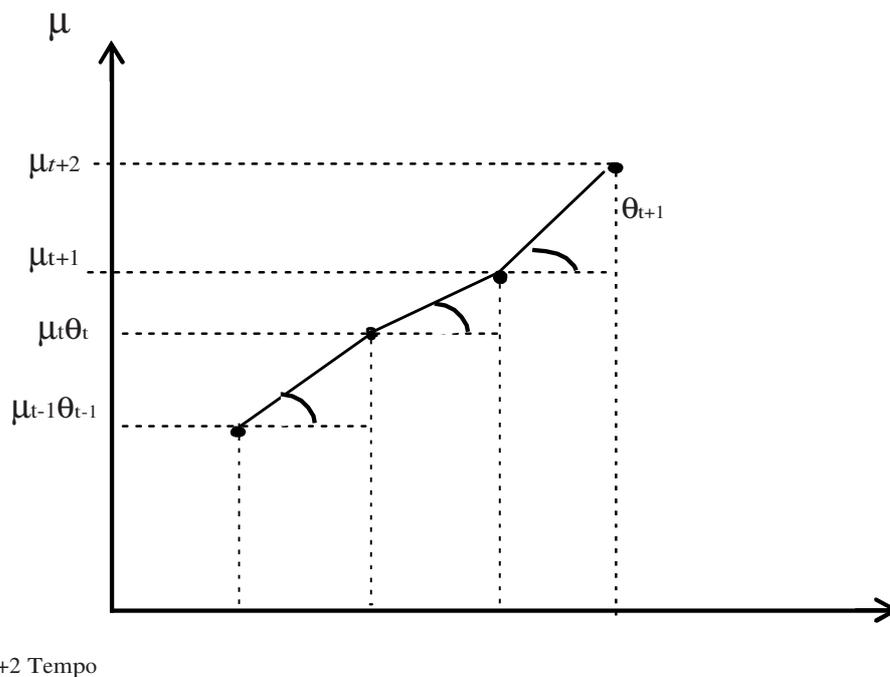
As três equações acima apresentam o modelo na sua forma estrutural. Para um entendimento mais intuitivo da forma estrutural proposta para a tendência (tendência local) considere-se uma versão não estocástica do modelo acima. Neste caso, obtemos:

$$\mu_t = \mu_{t-1} + \beta_{t-1}$$

$$y_t = \mu_t$$

Observando-se o gráfico, apresentado a seguir, é fácil verificar que a partir de um valor inicial para o nível (μ_{t-1}), e lembrando que $y_{t-1} = \mu_{t-1}$, podemos chegar a qualquer um dos valores dessazonalizados da variável escolhendo-se uma sequência apropriada para os β s ($\beta_{t-1}, \beta_t, \beta_{t+1}, \dots$). Abaixo, a tangente de θ_t é igual a β_t .

Gráfico - Tendência Local com Taxa de Crescimento



A versão não estocástica apresentada não é interessante, pois não permite projetar a tendência da série. Na versão estocástica estimam-se os valores de μ e β , ao longo do tempo (as variâncias dos resíduos são estimadas por máxima verossimilhança).

A forma reduzida do modelo estrutural apresentado é obtida observando-se que:

$$(1-L)\mu_t = \beta_{t-1} + \eta_t = \xi_{t-1}/(1-L) + \eta_t$$

$$\Leftrightarrow \mu_t = \xi_{t-1}/(1-L)^2 + \eta_t/(1-L)$$

$$(1-L)^2 y_t = \xi_{t-1} + \eta_t - \eta_{t-1} + \varepsilon_t - 2\varepsilon_{t-1} + \varepsilon_{t-2}$$

e, então, $y_t \sim \text{ARIMA}(0,2,2)$ com restrições nos parâmetros da parte MA.

Sem Taxa de Crescimento

No modelo sem taxa de crescimento a forma estrutural que permite identificar a tendência local é dada pelas seguintes equações:

$$y_t = \mu_t + \varepsilon_t, \quad \varepsilon_t \sim N(0, \sigma_\varepsilon^2)$$

$$\mu_t = \mu_{t-1} + \eta_t, \quad \eta_t \sim N(0, \sigma_\eta^2)$$

Na versão não estocástica o modelo acima se resumiria a: $\mu_t = \mu_{t-1}$ e $y_t = \mu_t$. Neste caso o nível da série é constante, dado o valor inicial μ_{t-1} .

Na versão estocástica estimam-se os valores de μ ao longo do tempo (as variâncias dos resíduos são estimadas por máxima verossimilhança). Neste caso, $(1-L)y_t = \eta_t + \varepsilon_t - \varepsilon_{t-1}$ e, portanto, na forma reduzida, $y_t \sim \text{ARIMA}(0,1,1)$ com restrições nos parâmetros da parte MA.

O Componente Sazonal

É usualmente modelado em termos de variáveis ‘*dummies*’ estocásticas (fatores sazonais) como

$$\gamma_t = -\sum_{j=1}^{s-1} \gamma_{t-j} + \omega_t, \quad \omega_t \sim N(0, \sigma_\omega^2)$$

Assim o componente sazonal (γ_t) pode se modificar no tempo, mas satisfazendo sempre a restrição de que a soma dos fatores sazonais em s períodos consecutivos tem esperança zero e variância constante.

Em termos de operador de defasagens L ,

$$(1+L+\dots+L^{s-1})\gamma_t = S(L)\gamma_t = \omega_t$$

Uma forma alternativa de modelar sazonalidade é através de uma série de senos e cossenos. O ‘efeito sazonal’ no tempo t é uma soma de fatores sazonais:

$$\gamma_t = \sum_{j=1}^{s/2} \gamma_{j,t}$$

A frequência sazonal é dada por $\lambda_j = 2\pi j / s$ onde os γ_s são definidos por:

$$\begin{bmatrix} \gamma_{j,t} \\ * \\ \gamma_{j,t} \end{bmatrix} = \begin{bmatrix} \cos \lambda_j & \text{sen } \lambda_j \\ -\text{sen } \lambda_j & \cos \lambda_j \end{bmatrix} + \begin{bmatrix} \gamma_{j,t-1} \\ * \\ \gamma_{j,t-1} \end{bmatrix} + \begin{bmatrix} \omega_{j,t} \\ * \\ \omega_{j,t} \end{bmatrix}$$

para $j=1, \dots, s/2-1$. Se $j=s/2$ então $\gamma_{j,t} = \cos \lambda_j \gamma_{j,t-1} + \omega_{jt}$

Além disso,

$$\begin{bmatrix} \omega_{j,t} \\ * \\ \omega_{j,t} \end{bmatrix} \sim N \left(\begin{bmatrix} 0 \\ 0 \end{bmatrix}, \begin{bmatrix} \sigma_\omega^2 & 0 \\ 0 & \sigma_\omega^2 \end{bmatrix} \right), \quad \forall t \text{ ou seja, as mudanças no padrão sazonal só dependem de um}$$

único parâmetro. Pode-se mostrar que:

$$(1 + L + \dots + L^{s-1})\gamma_t \sim \text{MA}(s-2)$$

Modelo Estrutural Completo

A seguir apresentamos o modelo estrutural completo com taxa de crescimento (inclinação) já que o modelo sem taxa é apenas um caso particular deste.

$$y_t = \mu_t + \gamma_t + \varepsilon_t, \quad \varepsilon_t \sim N(0, \sigma_\varepsilon^2)$$

$$\mu_t = \mu_{t-1} + \beta_{t-1} + \eta_t, \quad \eta_t \sim N(0, \sigma_\eta^2)$$

$$\beta_t = \beta_{t-1} + \xi_t, \quad \xi_t \sim N(0, \sigma_\xi^2)$$

$$\begin{bmatrix} \gamma_{j,t} \\ * \\ \gamma_{j,t} \end{bmatrix} = \begin{bmatrix} \cos \lambda_j & \text{sen } \lambda_j \\ -\text{sen } \lambda_j & \cos \lambda_j \end{bmatrix} + \begin{bmatrix} \gamma_{j,t-1} \\ * \\ \gamma_{j,t-1} \end{bmatrix} + \begin{bmatrix} \omega_{j,t} \\ * \\ \omega_{j,t} \end{bmatrix}, \quad \text{para } j = 1, \dots, s/2 - 1.$$

$$\gamma_{j,t} = \cos \lambda_j \gamma_{j,t-1} + \omega_{jt}, \quad \text{para } j=s/2, \quad \gamma_t = \sum_{j=1}^{s/2} \gamma_{j,t}$$

3.2 MODELOS MULTIVARIADOS

Quando duas ou mais variáveis parecem ter tendências relacionadas entre si é conveniente estudar suas tendências conjuntamente. O crescimento do comércio varejista, por exemplo, está relacionado com o crescimento do Imposto sobre Circulação de Mercadorias e Serviços (ICMS).

Para cada Série de Receita do Estado do Rio de Janeiro, foram elaborados e estimados os modelos multivariados VEC, BVEC e BVAR. As variáveis foram testadas do particular para o geral, começando a partir de um conjunto de variáveis sugeridas pelos técnicos da SEFAZ e utilizando uma especificação VAR (clássica) do modelo. Se alguma defasagem da variável, em alguma equação, apresentava um coeficiente significativamente diferente de zero, utilizando a estatística-t, ela era incluída no modelo. As variáveis cujos coeficientes eram mais significativamente diferentes de zero, segundo a estatística t, foram incluídas no modelo.

Especificação dos Modelos Multivariados

Para chegar às especificações dos modelos multivariados utilizados, para cada receita tributária, foram

feitos testes estatísticos (utilizando diversos softwares: Eviews, MATLAB, Stamp, etc.), pesquisas nos Boletins de Transferências Fiscais e obtidas informações diretamente da SEFAZ. Os Boletins de Transferências Fiscais estão disponibilizados no site da Secretaria de Fazenda do Estado do Rio de Janeiro (SEFAZ). Nos Boletins podem ser encontradas informações significativas sobre quais seriam as variáveis explicativas relevantes. No quadro 1 abaixo é apresentado um sumário indicando quais variáveis explicativas foram incluídas em que modelos multivariados para as receitas do estado do Rio de Janeiro.

ESPECIFICAÇÕES DOS MODELOS MULTIVARIADOS										
Variáveis Explicativas	Abrag.	ICMS	IPI	IPVA	IRRF	ITD	FECF	FPE	SE	SUS
Capacidade Instalada	RJ					X				
Comércio Varejista	RJ	X					X			
Consumo de Combustível	RJ			X						
Emprego Formal	RJ				X					
Internação	RJ									X
Massa Salarial	RJ								X	
População	RJ	X	X	X	X	X	X	X	X	X
Produção de Petróleo	RJ	X					X			
Produção Industrial	RJ	X			X					
Consumo de Energia Comercial	SE	X								
Consumo de Energia Industrial e Comercial	SE						X			
Consumo de Energia	BR		X							
Crédito de Automóvel	BR			X						
Crédito Imobiliário	BR					X				
IBC	BR		X							
Taxa de Câmbio	BR		X							
	Defasagem	2	1	1	2	2	2	2	2	1

Quadro 1 – Especificações dos modelos para as receitas tributárias (indicação das variáveis incluídas).

Fonte: Elaborada pelos próprios autores.

3.2.1 MODELO VETOR AUTO-REPRESSIVO BAYESIANO (BVAR)

O modelo VAR (p) pode ser escrito da seguinte forma:

$$y_t = d_t C + \sum_{i=1}^p y_{t-i} A_i + u_t, \quad t = 1, \dots, T,$$

para,

$$E(u_t | y_1, \dots, y_{t-1}, d_1, \dots, d_t) = \mathbf{0}_{1 \times n}$$

Onde: y_t é um vetor linha de variáveis endógenas, de dimensão $1 \times n$, no tempo t ; A_i são matrizes de

parâmetros de dimensão $n \times n$: C são matrizes $q \times n$ de parâmetros: d_t é um vetor linha $1 \times q$ de *dummies* sazonais e termo constante no tempo t ; u_t é um vetor linha $1 \times n$, de erros no tempo t ; p corresponde à extensão das defasagens e T é o tamanho da amostra. Os erros são independentes com distribuição Normal.

Um dos principais problemas ao se estimar um VAR irrestrito, como o da equação acima, através de MQO é que as estimativas dos coeficientes, quando p é moderadamente grande, não são muito precisas em amostras finitas.

Litterman (1980, 1986) discute este problema em um contexto no qual as séries de tempo exibem tendência ou nível local persistente e sugere um método Bayesiano de estimação alternativo. Litterman sugeriu considerar, na especificação das prioris para os parâmetros das regressões, passeios aleatórios para cada variável i :

$$y_{i,t} = y_{i,t-1} + u_{i,t}$$

Ou seja, a média da Priori para o parâmetro da variável na sua primeira defasagem seria considerada igual a 1 e as médias das Prioris para os parâmetros remanescentes seriam consideradas iguais a zero. Também é razoável que a importância das variáveis defasadas diminua com o tamanho da defasagem. Ou seja, as variâncias das Prioris dos parâmetros também diminuem com o tamanho da defasagem, apertando-se a distribuição a Priori em torno de zero.

A priori proposta por Litterman é frequentemente denominada Priori de Minnesota já que foi originado na Universidade de Minnesota e no Banco da Reserva Federal de Minneapolis. Apresentaremos a seguir como o método é implementado neste trabalho.

As prioris para os elementos individuais de cada matriz A , dos coeficientes defasados, são consideradas normais independentes com média de A_l ($l=1$) igual à identidade e com média de A_l igual a zero para $l > 1$. O desvio padrão para ij -ésimo coeficiente da matriz dos coeficientes das variáveis defasadas A_l é dado por:

$$\lambda_1 / l^{\lambda_3} \text{ se } i = j \text{ e}$$

$$\sigma_i \lambda_1 \lambda_2 / \sigma_j l^{\lambda_3} \text{ se } i \neq j,$$

onde σ_i é um fator de escala para lidar com a variabilidade na escala das variáveis e é o erro padrão residual de uma autorregressão Univariada da i -ésima variável.

O hiperparâmetro λ_1 é o desvio padrão da priori do ii -ésimo elemento da matriz A_l . Ao decrescermos o hiperparâmetro λ_2 , $0 < \lambda_2 \leq 1$, estamos forçando os parâmetros fora da diagonal de A_l para zero. O hiperparâmetro λ_3 , $\lambda_3 > 0$, controla até que ponto os coeficientes dos valores defasados das variáveis, para defasagens maiores do que um, são próximos de zero.

Para os coeficientes das *dummies* sazonais e para o termo constante adota-se o seguinte desvio padrão: $\lambda_4 \sigma_i$, onde λ_4 é um valor bastante grande. Ou seja, adota-se uma priori não-informativa para estes parâmetros.

Os valores usuais para os hiperparâmetros são: 0.05 para λ_1 , 0.005 para λ_2 , 1 para λ_3 e 10^5 para λ_4 .

Para uma discussão técnica das distribuições a priori e a posteriori, a equação do VAR(p) será reescrita da seguinte forma (para uma discussão mais detalhada ver Kadiyala e Karlsson (1997)):

$$y_t = z_t \Gamma + u_t$$

Onde $z_t = \{d_t, y_1, \dots, y_t\}$ e a matriz Γ , de dimensão $k \times nk = q + p$. n é dada por $(C'A', \dots, A'_p)$, q é o

número de variáveis exógenas que influenciam y_t .

Realizando os empilhamentos convencionais para os vetores coluna y_t, z_t e u_t para $t=1, \dots, T$ em Y, Z e U temos um modelo de regressão multivariado:

$$Y = Z \Gamma + U$$

Logo, deixando o índice i denotar o i -ésimo vetor coluna, tem-se a equação para a variável $i, y_i = Z y_i + u_i$. Para y, Y e u os vetores obtidos pelo empilhamento das colunas de Y, Γ e U , o sistema pode ser reescrito de forma:

$$y = (I \otimes Z) \gamma + u$$

No que se segue: “ \sim ” denota parâmetros da distribuição a priori e “ $_$ ” parâmetros da distribuição a posteriori. Os estimadores de MQO de Γ e γ são denotados por $\hat{\Gamma}$ e $\hat{\gamma}$, respectivamente.

Ao longo de toda a exposição, u_t é independente, identicamente distribuído e $u_t \sim N(0, \Psi)$ e $u_t \sim N(0, \Psi \otimes I)$.

A verossimilhança é dada por

$$L(\gamma, \Psi) \propto |\Psi|^{-T/2} \exp\{-tr[(Y - Z \Gamma)' \Psi^{-1} (Y - Z \Gamma)] / 2\}$$

Após algumas manipulações, nós chegamos a

$$L(\gamma, \Psi) \propto |\Psi|^{-T/2} \exp\left\{-\frac{1}{2}(y - \hat{y})' (\Psi^{-1} \otimes Z' Z) (y - \hat{y})\right\} \times |\Psi|^{-T/2}$$

$$= |\Psi|^{-k/2} \exp\left\{-\frac{1}{2}(\gamma - \hat{\gamma})' (\Psi^{-1} \otimes Z' Z) (\gamma - \hat{\gamma})\right\} \times |\Psi|^{-T/2}$$

$$\times \exp\left\{-\frac{1}{2}tr[\Psi^{-1} (Y - Z \hat{\Gamma})' (Y - Z \hat{\Gamma})]\right\}$$

$$L(\gamma, \Psi) \propto N(\gamma | \hat{\gamma}, \Psi \otimes (Z' Z)^{-1}) \times iW(\Psi | (Y - Z \hat{\Gamma})' (Y - Z \hat{\Gamma}), T - k - n - 1)$$

Ou seja, a verossimilhança é proporcional ao produto de uma densidade Wishart inversa para Ψ e uma densidade Normal para Y condicional em Ψ .

Em diversos trabalhos se utiliza uma priori Normal-difusa (Priori de Jeffrey) para parâmetros do modelo autorregressivo. Isto é, nós temos **prioris independentes** para γ e Ψ dadas por:

$$\gamma \sim N(\tilde{\gamma}, \tilde{\Sigma}) \quad e \quad p(\Psi) \propto |\Psi|^{-(n+1)/2}$$

A posteridade de Γ é dada por:

$$p(\gamma | y) \propto \exp\left\{-\frac{1}{2}(\gamma - \tilde{\gamma})' \tilde{\Sigma}^{-1} (\gamma - \tilde{\gamma}) / 2\right\} \times$$

$$| (Y - Z \hat{\Gamma})' (Y - Z \hat{\Gamma}) + (\Gamma - \hat{\Gamma})' Z' Z (\Gamma - \hat{\Gamma}) |^{-T/2}$$

Seja $\bar{\gamma} \equiv (\tilde{\Sigma}^{-1} + \Psi^{-1} \otimes Z' Z)^{-1} (\tilde{\Sigma}^{-1} \tilde{\gamma} + (\Psi^{-1} \otimes Z' Z) \hat{\gamma})$. Após algumas manipulações, a distribuição

condicional a posteriori de y é dada por:

$$\gamma \mid \Psi, y \sim N(\bar{\gamma}, (\tilde{\Sigma}^{-1} + \Psi^{-1} \otimes Z'Z)^{-1})$$

$$\Psi^{-1} \mid \gamma, y \sim W([Y - Z\hat{\Gamma}]'(Y - Z\hat{\Gamma}) + (\Gamma - \hat{\Gamma})'Z'Z(\Gamma - \hat{\Gamma})]^{-1}, T)$$

Seguindo um enfoque bayesiano, tratamos os parâmetros do modelo $\theta = (\gamma, \Psi)$ como variáveis aleatórias. O algoritmo do Amostrador de Gibbs, proposto por Kadiyala e Karlsson (1997) é fácil de implementar, comutando-se entre as duas últimas equações apresentadas e usando o algoritmo dado por Geweke (1988) para o sorteio de γ . O **Amostrador de Gibbs** é um método de Monte Carlo com cadeias de Markov que permite fazer extrações de distribuições conjuntas ou marginais a partir de extrações das distribuições condicionais.

3.2.2 MODELO VETOR DE CORREÇÃO DE ERROS (VEC)

O Teorema da Representação de Granger relaciona cointegração com modelos de correção de erros. Johansen (1988) relaciona cointegração e modelos de correção de erros utilizando o arcabouço dos modelos Autorregressivos Vetoriais. A seguir explicitaremos a abordagem de Johansen na modelagem de cointegração.

Considere o seguinte VAR(p) para o vetor ($n \times 1$) Y_t :

$$Y_t = \Phi D_t + \Pi_1 Y_{t-1} + \dots + \Pi_p Y_{t-p} + \varepsilon_t$$

Onde:

$t = 1, \dots, T$, ($T =$ tamanho da amostra); D_t = termo determinístico; Φ e Π_i ($i = 1, \dots, p$) são matrizes de parâmetros.

Se as variáveis em Y_t são integradas de ordem 1 elas podem cointegrar. Se Y_t é cointegrável então a representação VAR não é a mais adequada por que a informação dada pelas relações de cointegração não estão sendo utilizadas. As informações contidas nas relações de cointegração passam a ser utilizadas se o VAR no nível é transformado em um modelo de vetor de correção de erros (VEC – Vector Error Correction Model).

$$\Delta Y_t = \Phi D_t + \Pi Y_{t-1} + \Gamma_1 \Delta Y_{t-1} + \dots + \Gamma_{p-1} \Delta Y_{t-p+1} + \varepsilon_t$$

$$\Pi = \Pi_1 + \dots + \Pi_p - I_n$$

Onde:

$$\Gamma_k = - \sum_{j=k+1}^p \Pi_j, \quad k=1, \dots, p-1.$$

No VEC ΔY_t e seus retardos são integráveis de ordem “zero” (são estacionários). O termo ΠY_{t-1} é o único que inclui variáveis que são potencialmente integradas de ordem 1 e, para que ΔY_t seja estacionário é necessário que ΠY_{t-1} seja estacionário.

Portanto, ΠY_{t-1} precisa contar as relações de cointegração se elas existirem. Se Π é singular então ela é de posto reduzido, ou seja, $\text{posto}(\Pi) = r < n$ ($n =$ dimensão do vetor Y_t). Se $\text{posto}(\Pi) > 0$ então Y_t é I(1)

(integrado de ordem 1) com r vetores de cointegração linearmente independentes e $n - r$ tendências estocásticas comuns (raízes unitárias). Como Π tem posto r ele pode ser reescrito como sendo o seguinte produto:

$$\Pi = \alpha \beta'$$

$(n \times n)$ $(n \times r)$ $(r \times n)$

Onde: α e β são $(n \times r)$ matrizes com $\text{posto}(\alpha) = \text{posto}(\beta) = r$. As colunas de β' formam uma base para os r vetores de cointegração e os elementos de α distribuem o impacto dos desvios das relações de cointegração na evolução de ΔY_t . O VEC então é dado por:

$$\Delta Y_t = \Phi D_t + \alpha \beta' Y_{t-1} + \Gamma_1 \Delta Y_{t-1} + \dots + \Gamma_{p-1} Y_{t-p+1} + \varepsilon_t$$

onde β é o vetor de cointegração.

3.2.3 MODELO VETOR DE CORREÇÃO DE ERROS BAYESIANO (BVEC)

A representação VAR não permite introduzir facilmente as restrições impostas pela existência de cointegração e, neste caso, é conveniente a utilização da representação VEC.

Representação VEC

Nas equações abaixo cada elemento de Y_t , por hipótese, é $I(1)$. Então, se existe cointegração entre as variáveis o modelo é mais facilmente estimado na representação VEC utilizando o procedimento proposto por Johansen (1988). A representação VEC do modelo na forma reduzida é apresentada a seguir:

$$\Gamma(L)\Delta Y_t = \Phi D_t - \alpha \beta' Y_{t-1} + \varepsilon_t$$

Onde: $\Gamma_0 = I$; β = vetor de cointegração; $\beta' Y_t$ = relação de cointegração.

As matrizes α e β são $n \times r$ e têm posto r , onde r é o número de relações de cointegração existente entre as variáveis. Já $\beta' Y_t$ é estacionária ($I(0)$) e dá o desvio das variáveis em relação a sua trajetória de longo prazo (i.e., é a relação de cointegração).

O procedimento clássico de estimação, desenvolvido por Johansen, consiste em utilizar as propriedades de integração e cointegração dos dados para impor restrições nos coeficientes da forma reduzida do modelo. O procedimento de Johansen permite, entre outras coisas, estimar β e o número de relações de cointegração.

Procedimento Bayesiano de Estimação do VEC (BVEC)

O procedimento bayesiano adotado consiste em postular no início da amostra, para cada coeficiente de cada equação, prioris com distribuição normal e independentemente distribuídas. Todas as prioris têm média zero e variância que é fixada arbitrariamente. O procedimento bayesiano adotado consiste em utilizar a estimativa de α , obtida através do procedimento de Johansen para estimar, através de um procedimento bayesiano, ρ , θ , γ e $H(L)$, que são os parâmetros da equação acima, tratando-se o valor estimado de α como dado.

O procedimento bayesiano postula no início da amostra, para cada coeficiente de cada equação, da representação VEC (à exceção de β , que é tratado como dado), Prioris com distribuição normal

e independentemente distribuídas. Os coeficientes, das equações, foram estimados conjuntamente através do amostrador de Gibbs. Todas as prioris dos coeficientes têm média zero e desvio padrão que é fixado arbitrariamente. Os desvios padrões das prioris dos parâmetros de cada equação i , de cada modelo desenvolvido, dependem de um vetor de parâmetros de dimensão $(neq + 5)$, $neq =$ número de variáveis endógenas do VEC) que foi fixado com o objetivo de se incrementar habilidade preditiva do modelo. A matriz de parâmetros λ , de dimensão $(neq + 5) \times neq$, de cada modelo foi escolhida com o objetivo de se reduzir o erro médio absoluto nas previsões 12 meses à frente da variável de interesse.

A seguir é explicitado como os desvios padrões das prioris dos coeficientes de cada modelo são fixados a partir da matriz de parâmetros λ :

- Os desvios padrões, das distribuições a priori dos parâmetros dos valores defasados das variáveis contidos em $\Gamma(L)$, foram fixados utilizando-se a seguinte especificação (Priori de Litterman):

$$\sigma_{ij}^L = (\tau_i / \tau_j)(\lambda(j,i)/L); i = 1,2,\dots,6; j = 1,2,\dots,6; L = 1,2,\dots,12;$$

Onde: $\sigma_{ij}^L =$ desvio padrão do coeficiente da variável j , com defasagem L , na equação da variável i ; $\tau_i =$ desvio padrão, da variável i , estimado através de uma autorregressão univariada onde a variável i entra com defasagens; $\lambda(j,i) =$ coeficiente de abertura (*tightness*) fixado arbitrariamente para a variável j na equação i .

- O desvio padrão da priori do termo constante na equação $i = \lambda(neq + 1,i)$. ($neq =$ número de variáveis endógenas);
- O desvio padrão da priori dos parâmetros das *dummies* sazonais na equação $i = \lambda(neq + 2,i)$. ($neq =$ número de variáveis endógenas);
- O desvio padrão dos parâmetros das variáveis exógenas na equação $i = \lambda(neq + 3,i)$. ($neq =$ número de variáveis endógenas);
- O desvio padrão da priori dos parâmetros das variáveis de intervenção na equação $i = \lambda(neq + 4,i)$. ($neq =$ número de variáveis endógenas);

O desvio padrão da priori dos parâmetros indicadores dos pesos das relações de cointegração (uma equação do VEC) na equação $i = \lambda(neq + 5,i)$. ($neq =$ número de variáveis endógenas).

4. ANÁLISE DOS RESULTADOS

4.1 DADOS

Variáveis Explicativas

Estão listadas, no quadro 4.1.1, as 16 variáveis explicativas que foram coletadas e que foram utilizadas na construção dos modelos multivariados para as principais receitas tributárias do Estado. As variáveis foram coletadas em diversas fontes: IBGE, BACEN, ELETROBRAS, etc. No entanto, algumas não apresentaram observações suficientes para serem incluídas nos modelos, fazendo-se necessário o uso de BackCast para não reduzirmos o período amostral considerado na estimação dos modelos.

Variáveis Explicativas	VARIÁVEIS AVALIADAS			
	Período		Abrangência regional	Fonte
	Início	Fim		
Capacidade Instalada	Jan/03	Abr/12	RJ	FIRJAN
Comércio Varejista	jan/00	abr/12	RJ	IBGE
Consumo de Combustível	jan/00	mar/12	RJ	IBGE
Consumo de Energia	jan/99	abr/12	BR	ELETOBRAS
Consumo de Energia Comercial	jan/99	Abr/12	SE	BACEN
Consumo de Energia Industrial e comercial	Jan/99	Abr/12	SE	BACEN
Crédito de Automóvel	Jan/04	Abr/12	BR	BACEN
Crédito Imobiliário	Jan/04	Abr/12	BR	BACEN
Emprego Formal	Jan/99	Abr/12	RJ	IBGE
IBC	Jan/03	Abr/12	BR	BACEN
Massa Salarial	Jan/03	Abr/12	RJ	FIRJAN
Internação	Jan/99	Abr/12	RJ	DATASUS
População	Jan/99	Abr/12	RJ	IBGE
Produção de Petróleo	Jan/99	Abr/12	RJ	ANP
Produção Industrial	Jan/99	Mar/12	RJ	IBGE
Taxa de Câmbio	Jan/99	Abr/12	BR	BACEN

Quadro 4.1.1 – Descrições das Variáveis Explicativas Coletadas

Nota: Abrangência regional: RJ, (Estado do Rio de Janeiro), SE (Sudeste) e BR (Brasil).

Fonte: Elaborada pelos próprios autores.

Séries de Receita do Estado do Rio de Janeiro

Estão listadas, no quadro 4.1.2, as séries de receita do Estado do Rio de Janeiro que foram utilizadas na construção dos modelos de previsão das receitas tributárias do estado. Todas as variáveis tem periodicidade mensal com exceção da CIDE que tem periodicidade trimestral.

Série	PERÍODO DAS AMOSTRAS	
	Período	
	Início	Fim
CIDE ¹	abr/02	abr/12
FECF ²	out/03	abr/12
FPE	jan/99	abr/12
ICMS	jan/99	abr/12
IPI	jan/99	abr/12
IPVA	jan/99	abr/12
IRRF	jan/99	abr/12
ITCMD	jan/99	abr/12
SE ³	jan/99	abr/12
SUS ⁴	jan/02	abr/12

Quadro 4.1.2 – Períodos cobertos pelas Amostras das Séries de Receita do Estado do Rio de Janeiro.

Notas: Alterações do início da amostra devido a fortes alterações nos padrões das séries:

¹CIDE – a amostra utilizada tem início em abr/2004.

²FECF – a amostra utilizada tem início em em nov/2003.

³SE – a amostra utilizada tem início em nov/2006.

⁴SUS – a amostra do modelo multivariado tem início em abr/2004 e a do modelo univariado tem início em abr/2005.

Fonte: Elaborada pelos próprios autores.

4.2 TESTES ESTATÍSTICOS

4.2.1 TESTES ESTATÍSTICOS – MODELOS UNIVARIADOS

A estimação dos modelos univariados é fundamental já que estes modelos tendem a apresentar habilidade preditiva superior à dos modelos multivariados. São bastante úteis, pois além de preverem bem, servirão como base para avaliar a qualidade da habilidade preditiva dos modelos multivariados.

Especificação dos Modelos das Séries de Receita do Estado do Rio de Janeiro

Foram estimados, para cada variável-alvo, modelos SARIMA (modelos ARIMA com componentes sazonais) e modelos univariados estruturais com componentes não observáveis, em que a série é decomposta em seus componentes principais: nível, tendência, sazonalidade, ciclo e componente irregular. A partir dos modelos SARIMA obtidos no Software Demetra detectamos as quebras estruturais, os valores atípicos (*Outliers*) e quebras de nível, observadas no processo gerador das séries.

Como pode ser visto no quadro 4.2.1 foram detectadas diversas quebras estruturais no período de janeiro de 1999 a abril de 2012.

Séries	Datas das Quebras Estruturais (As duas primeiras letras indicam o tipo de Quebra)								
	FECF	FPE	ICMS	IPI	IPVA	IRRF	ITCMD	SE	SUS
Intervenções	AO[2004-03]	LS[2002-3]	AO[2004-01]	AO[1999-03]	LS[1999-08]	AO[1999-08]	AO[2010-04]	AO[2008-02]	LS[2005-04]
	AO[2004-06]	-	-	LS[2004-03]	LS[2000-02]	AO[1999-09]	-	AO[2008-03]	LS[2007-01]
	AO[2004-12]	-	-	AO[2008-12]	AO[2001-01]	AO[2005-04]	-	-	AO[2011-10]
	LS[2003-10]	-	-	-	-	AO[2008-08]	-	-	AO[2012-03]
	-	-	-	-	-	AO[2009-11]	-	-	-
	-	-	-	-	-	AO[2010-06]	-	-	-
	-	-	-	-	-	AO[2011-04]	-	-	-

Séries	Datas das Quebras Estruturais (As duas primeiras letras indicam o tipo de Quebra)
Intervenções	AO[2004-07]
	AO[2009-04]

Quadro 4.2.1 – Quebras Estruturais das Séries de Receita do Estado do Rio de Janeiro.

Nota: Outliers (AO) e Quebra de nível (LS).

Fonte: Elaborada pelos próprios autores.

Para especificarmos os modelos univariados estruturais, as séries de Receita do Estado do Rio de Janeiro, foram testadas 8 (oito) formulações diferentes utilizando um pacote estatístico,

desenvolvido por nós, em linguagem MatLab.

Foi selecionado, para cada variável, o modelo com o menor erro percentual nas previsões acumuladas para os doze meses seguintes à data em que as previsões foram obtidas (ou seja, para obter o erro foram acumuladas as previsões de 1 (um) até 12 (doze) meses à frente e este valor foi comparado com o valor observado). Estas previsões foram efetuadas em todas as datas a partir de determinado ponto da amostra (escolhido para se obter graus de liberdade suficientes) e até o final da amostra. Foram utilizados, em cada data na qual a previsão foi feita, os parâmetros do modelo estimados utilizando-se apenas informações amostrais até aquela data. Ou seja, foram feitas previsões “fora da amostra” (*out of sample*). As estimativas dos parâmetros, em cada ponto na amostra, foram obtidas recursivamente utilizando-se o filtro de Kalman.

Na especificação dos componentes do modelo foram testados: nível estocástico ou fixo; inclinação fixa ou estocástica; existência ou não de sazonalidade e seu tipo – trigonométrica ou com *dummies*. No Stamp foram feitos testes adicionais dos modelos utilizando-se análises gráficas e diversas estatísticas de ajustes, de habilidade preditiva e de distribuição dos resíduos dos modelos. O quadro 4.2.2 apresenta os modelos escolhidos.

Os modelos estimados apresentaram boa habilidade preditiva, como podemos constatar pela análise do quadro 4.2.2. As estatísticas das habilidades preditivas dos modelos das séries de Receita do estado do Rio de Janeiro foram computadas com dados mensais, com exceção das estatísticas do modelo para a CIDE onde a periodicidade foi trimestral. Para a CIDE foi escolhido um modelo com nível estocástico, sem inclinação e com sazonalidade fixa.

	ERRO PERCENTUAL EM PREVISÕES ANUAIS DAS SÉRIES DE RECEITA							
	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8
FECF	2,34	4,38	1,83	2,11	2,11	2,72	1,85	5,8
FPE	5,1	7,99	5,1	5,35	5,35	5,05	5,05	5,19
ICMS	4,45	6,02	4,45	11,05	11,05	5	4,45	3,79
IPI	11,12	14,02	11,12	6	6	10,66	11,13	11,23
IPVA	11,51	10,09	11,51	3,02	3,02	26,34	12,15	11,2
IRRF	20,83	24,44	20,75	7,89	7,89	21,29	20,75	22,57
ITCMD	13,08	20,36	15,23	23,26	23,26	16,23	15,23	14,22
SE	3,86	15,62	20,23	20,23	20,23	10,66	20,06	18,43
SUS	16,94	14,49	20,17	40,78	40,78	19,16	20,26	21,82

Quadro 4.2.2 – Especificação dos Modelos Univariados Estruturais das Séries de Receita do Estado do Rio de Janeiro.

Notas:

Modelo 1: Com AR (1), Nível estocástico, Inclinação estocástica e Sazonalidade trigonométrica.

Modelo 2: Com AR (1), Nível estocástico, Sem inclinação e Sazonalidade trigonométrica.

Modelo 3: Com AR (1), Nível estocástico, Inclinação fixa e Sazonalidade trigonométrica.

Modelo 4: Com AR (1), Nível fixo, Inclinação estocástica e Sazonalidade trigonométrica.

Modelo 5: Com AR (1), Nível fixo, Inclinação fixa e Sazonalidade trigonométrica.

Modelo 6: Com AR (1), Nível estocástico, Inclinação fixa e Sem sazonalidade.

Modelo 7: Com AR (1), Nível estocástico, Inclinação fixa e Sazonalidade com dummies.

Modelo 8: Sem AR (1), Nível estocástico, Inclinação fixa e Sazonalidade trigonométrica.

Fonte: Elaborada pelos próprios autores.

4.2.2 TESTES ESTATÍSTICOS – MODELOS MULTIVARIADOS

Uma série diferença-estacionária é denominada I(d) se ela pode ser transformada em uma série estacionária após se tomar d diferenças. A letra d denota a ordem de integração da série e é igual ao número de raízes unitárias contidas na série.

Para obter o número de raízes unitárias das séries foi utilizado o teste de Phillips- Perron. Esse teste é robusto na presença de observações distribuídas de forma heterogênea e com fraca dependência. Para tanto, estima-se numericamente a variância de longo prazo (que inclui todas as autocovariâncias do processo) dos resíduos por meio da densidade espectral da variável dependente na frequência zero. Os resultados são apresentados no Quadro 4.2.2.1.

VARIÁVEIS EXPLICATIVAS	TESTE DE RAIZ UNITÁRIA		
	PP	SÉRIES	PP
Capacidade Instalada	I(1)	CIDE	I(1)
Comércio Varejista	I(0)	FECF	I(0)
Consumo de Combustível	I(1)	FPE	I(0)
Consumo Energia (Nac.)	I(1)	ICMS	I(0)
Consumo de Energia - Comercial	I(1)	IPI	I(1)
Consumo de Energia Indust.+Com.	I(1)	IPVA	I(0)
Crédito de Automóvel	I(1)	IRRF	I(0)
Crédito Imobiliário	I(1)	ITCMD	I(0)
Emprego Formal	I(1)	SE	I(0)
IBC	I(1)	SUS	I(0)
Internação	I(0)		
Massa Salarial	I(1)		
População	I(1)		
Produção de Petróleo	I(1)		
Produção Industrial	I(0)		
Taxa de Câmbio	I(1)		
Frota de Automóvel (Trimestral)	I(1)		
População (Trimestral)	I(1)		

Quadro 4.2.2.1 – Ordem de Integração das Variáveis - Teste de Philips-Perron.

Fonte: Elaborada pelos próprios autores.

As quebras estruturais detectadas, para cada série de dados e na estimação dos modelos univariados, foram mantidas nos modelos multivariados quando permaneceram significantes. Foram utilizadas diversas intervenções no período de Janeiro de 1999 a Abril de 2012,

apresentadas no quadro 4.2.2.2.

Séries	OUTLIERS (AO) E QUEBRA DE NÍVEL (LS)								
	FECF	FPE	ICMS	IPI	IPVA	IRRF	ITCMD	SE	SUS
Intervenções	AO[2004-06]	AO[2001-07]	AO[2001-06]	AO[2008-12]	-	AO[2001-12]	AO[2009-08]	AO[2008-02]	AO[2011-10]
	AO[2004-12]	AO[2002-05]	AO[2001-10]	AO[2011-09]	-	AO[2005-04]	AO[2010-04]	AO[2008-03]	AO[2012-03]
	AO[2008-03]	-	AO[2004-01]	AO[2012-01]	-	AO[2007-02]	LS[2001-06]	-	LS[2005-04]
	AO[2012-01]	-	AO[2007-06]	LS[2003-03]	-	AO[2008-08]	-	-	LS[2007-01]
	LS[2006-01]	-	LS[2001-07]	LS[2007-05]	-	AO[2009-11]	-	-	-
	LS[2008-11]	-	LS[2001-12]	LS[2008-11]	-	AO[2010-06]	-	-	-
	-	-	LS[2003-03]	LS[2008-12]	-	AO[2011-04]	-	-	-
	-	-	LS[2008-06]	LS[2009-06]	-	LS[2007-01]	-	-	-
	-	-	LS[2008-12]	LS[2010-03]	-	LS[2007-04]	-	-	-

OUTLIERS (AO) E QUEBRA DE NÍVEL (LS)	
Modelo	CIDE
Intervenções	AO[2004-07]
	AO[2009-04]

Quadro 4.2.2.2 – Quebras estruturais dos Modelos Multivariados.

Fonte: Elaborada pelos próprios autores.

4.3 SELEÇÃO DOS MODELOS DE PREVISÃO DA RECEITA

4.3.1 MODELOS UNIVARIADOS

Várias medidas têm sido propostas para testar a capacidade preditiva dos modelos econométricos. Dentre as mais utilizadas está o Theil-U. Esta estatística compara os erros de previsão do modelo a ser testado com os erros de previsão de um Modelo *Naive* no qual a variável segue um passeio aleatório (*random walk*). No Modelo *Naive* prevê-se que a variável, nos diversos períodos (passos) à frente, terá um valor igual ao observado na data imediatamente anterior ao período de previsão.

Os modelos univariados estimados apresentaram boa habilidade preditiva, como podemos constatar pela análise do quadro 4.3.1.1. As estatísticas das habilidades preditivas dos modelos das séries de Receita do estado do Rio de Janeiro foram computadas com dados mensais, com exceção das estatísticas do modelo para a CIDE onde a periodicidade foi trimestral. As estatísticas da habilidade preditiva do modelo para a CIDE encontram-se em destaque na Tabela 4.3.1.2.

Tabela 4.3.1.1 - Habilidade Preditiva das Séries de Receitas do Estado do Rio de Janeiro.

Passos a Frente	Num Obs.	THEIL-U								
		FECP	FPE	ICMS	IPI	IPVA	IRRF	ITCMD	SE	SUS
		Modelo 5	Modelo 8	Modelo 5	Modelo 5	Modelo 1	Modelo 1	Modelo 7	Modelo 2	Modelo 3
1	33	0,842	0,459	0,698	0,82	0,174	0,619	0,746	0,236	0,693
2	32	0,797	0,431	0,677	0,818	0,107	0,573	0,634	0,225	0,845
3	31	0,778	0,391	0,666	0,668	0,101	0,567	0,653	0,269	0,889
4	30	0,717	0,392	0,703	0,769	0,095	0,576	0,71	0,309	0,858
5	29	0,674	0,396	0,679	0,728	0,096	0,514	0,697	0,259	1,561
6	28	0,666	0,507	0,651	0,836	0,096	0,604	0,664	0,25	0,899
7	27	0,709	0,382	0,762	0,761	0,091	0,564	0,763	0,251	0,926
8	26	0,78	0,429	0,779	0,807	0,096	0,582	0,921	0,306	0,987
9	25	0,746	0,401	0,697	0,734	0,102	0,493	0,667	0,27	0,979
10	24	0,874	0,39	0,756	0,88	0,122	0,545	0,392	0,28	1,203
11	23	0,852	0,43	0,775	0,728	0,171	0,475	0,327	0,286	1,015
12	22	0,856	0,695	0,847	0,699	1,008	0,557	0,374	0,734	0,905

Fonte: Elaborada pelos próprios autores.

THEIL-U (CIDE)		
Passos a Frente	Num Obs.	CIDE
1	10	0,976
2	9	0,982
3	8	1,053
4	7	0,997
5	6	0,983
6	5	0,956
7	4	0,799
8	3	0,934
9	2	1,015

Quadro 4.3.1.2

Fonte: Elaborada pelos próprios autores.

Apresentamos na tabela abaixo a escolha dos modelos das variáveis explicativas que foram utilizadas nos modelos multivariados.

Tabela 4.3.1.3 - Modelos Estruturais das Variáveis Explicativas

Variáveis	ERRO PERCENTUAL NAS PREVISÕES ANUAIS (12 MESES À FRENTE) DAS VARIÁVEIS EXPLICATIVAS							
	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5	Modelo 6	Modelo 7	Modelo 8
	Capacidade Instalada	2.4	3.45	2.4	4.32	4.32	2.83	2.4
Comércio Varejista	2.36	4.84	2.65	4.52	4.52	4.73	2.59	2.64
Consumo de Combustível	3.78	3.11	3.85	5.43	5.43	4.42	3.85	3.94
Consumo de Energia(Nac.)	0.98	2.32	0.98	0.98	0.98	1.07	1.02	1.39
Consumo de Energia Comercial	1.24	3.42	1.34	1.25	1.25	1.9	1.34	1.29
Consumo de Energia Indust.+ Com.	2.11	1.63	2.11	1.92	1.92	2.56	2.17	2.02
Crédito Imobiliário	4.8	12.13	15.77	3.64	3.64	4.49	-	-
Crédito para Automóvel	3.02	2.89	2.21	4.74	4.74	2.29	2.2	2.09
Emprego Formal	1.28	1.14	1.3	8.54	8.54	1.45	1.3	1.2
IBC	1.11	1.51	1.06	1.33	3.39	0.69	1.06	1.03
Internação	2.05	1.86	2.05	6.14	6.14	2.61	1.97	2.04
Massa Salarial	1.74	3.83	1.74	3.29	3.29	2.52	1.74	1.72
Produção de Petróleo	10.9	12.48	7.51	8.35	8.35	5.81	7.51	10.96
Produção Industrial	2.55	2.86	2.55	4.52	4.52	2.84	2.54	2.55
Taxa de Câmbio	4.13	4.99	4.13	4.85	4.85	4.69	4.13	4.2

Fonte: Elaborada pelos próprios autores.

4.3.2 MODELOS MULTIVARIADOS

Várias medidas têm sido propostas para se testar a capacidade preditiva dos modelos econométricos. Nesse caso calculamos o Theil-U e o erro percentual em previsões anuais (descrito anteriormente). Para cada série de receita o melhor modelo multivariado foi aquele que apresentou o menor erro percentual em previsões anuais (acumulando as previsões de 1 até 12 passos à frente). Na escolha do número de defasagens do modelo foi considerado o critério de informação Schwartz. Devido ao pequeno tamanho da amostra o melhor modelo para a CIDE foi escolhido observando-se os Theil-Us em até quatro trimestres à frente.

A seguir apresentamos a seleção dos melhores modelos de previsão das receitas do Estado do Rio de Janeiro.

CIDE

Com base na estatística-t as variáveis explicativas que apresentaram melhor nível de significância para o modelo multivariado foram: População e Frota de Automóveis.

A habilidade preditiva do modelo VEC se mostrou melhor que os demais, como se pode ver na Tabela 4.3.2.1 apresentada abaixo.

Tabela 4.3.2.1 - Habilidade Preditiva da CIDE.

Trimestres à frente	Num. Obs.	THEIL-U – CID			
		BVAR	BVEC	VEC	UNIVARIADO
1	10	1.02	0.85	0.85	0.976
2	9	0.73	0.65	0.64	0.982
3	8	0.82	0.76	0.75	1.053
4	7	0.86	0.81	0.81	0.997
5	6	0.76	0.83	0.83	0.983
6	5	0.81	0.95	0.95	0.956
7	4	1.06	0.97	0.99	0.934
8	3	0.86	0.67	0.67	0.934

Fonte: Elaborada pelos próprios autores.

FECP

Com base na estatística-t e informações advindas diretamente da SEFAZ, as variáveis explicativas que apresentaram melhor nível de significância para o modelo multivariado foram: População (RJ), Comércio Varejista (RJ), Produção de Petróleo (RJ) e Consumo de Energia Industrial e Comercial (SE).

O modelo VEC possui o menor erro percentual em previsões anuais e foi o modelo multivariado escolhido. Para previsões de curto prazo o modelo BVAR é o que apresenta melhor precisão entre os multivariados, já para previsões de longo prazo o melhor modelo é o VEC, como podemos constatar pela análise da Tabela 4.3.2.2. Nas previsões de 1 até 2 passos à frente o modelo univariado é o melhor.

Tabela 4.3.2.2 - Habilidade Preditiva da FECP.

Série	ERRO ANUAL DO MODELO MULTIVARIADO			ERRO ANUAL DO MODELO UNIVARIADO
	BVAR (%)	BVEC (%)	VEC (%)	
FECP	2.91	1.04	0.89	2.82

Tabela 4.3.2.2 - Habilidade Preditiva da FECF.

(Continuação)

Passo à frente	Num. Obs.	THEIL-U – FECF			
		BVAR	BVEC	VEC	UNIVARIADO
1	33	0.95	1.03	1.04	0.774
2	32	0.91	1.01	0.95	0.791
3	31	0.78	0.86	0.81	0.833
4	30	0.72	0.74	0.73	0.777
5	29	0.68	0.68	0.65	0.737
6	28	0.68	0.68	0.66	0.740
7	27	0.67	0.66	0.63	0.784
8	26	0.8	0.77	0.74	0.870
9	25	0.76	0.73	0.7	0.824
10	24	0.9	0.84	0.81	0.950
11	23	0.91	0.8	0.8	0.887
12	22	0.89	0.82	0.79	0.884

Fonte: Elaborada pelos próprios autores.

FPE

Com base na estatística-t, as variáveis explicativas que apresentaram melhor nível de significância para o modelo multivariado foram: População (RJ), IBC e Taxa de Câmbio.

A habilidade preditiva do modelo BVAR se mostrou melhor que os demais analisando o erro percentual em previsões anuais do modelo, por isso foi o modelo escolhido. Para previsões de curto, médio e longo prazos o modelo BVAR continua sendo o que apresenta melhor precisão, como podemos constatar pela análise da Tabela 4.3.2.3.

Tabela 4.3.2.3 - Habilidade Preditiva da FPE.

Série	ERRO ANUAL DO MODELO MULTIVARIADO			ERRO ANUAL DO MODELO UNIVARIADO (%)
	BVAR (%)	BVEC (%)	VEC (%)	
FPE	3.45	3.63	3.93	5.48

Passos à frente	Num. Obs.	THEIL-U – FPE			
		BVAR	BVEC	VEC	UNIVARIADO
1	33	0.5	0.54	0.57	0.510
2	32	0.45	0.44	0.47	0.475
3	31	0.42	0.43	0.45	0.428
4	30	0.43	0.42	0.44	0.436
5	29	0.42	0.41	0.43	0.428
6	28	0.47	0.47	0.51	0.563
7	27	0.38	0.38	0.41	0.419
8	26	0.37	0.37	0.38	0.476
9	25	0.35	0.35	0.36	0.430
10	24	0.37	0.37	0.38	0.430
11	23	0.38	0.38	0.41	0.466
12	22	0.62	0.62	0.68	0.756

Fonte: Elaborada pelos próprios autores.

ICMS

Com base na estatística-t e partindo de um conjunto de variáveis indicada pela SEFAZ, as variáveis explicativas que apresentaram melhor nível de significância para o modelo multivariado foram: População (RJ), Produção Industrial (RJ), Comércio Varejista (RJ), Consumo de Energia Comercial (SE -Sudeste) e Produção de Petróleo (RJ).

A habilidade preditiva do modelo univariado apresentou melhor resultado em previsões anuais. Porém, entre os modelos multivariados, o modelo BVEC se mostrou melhor que os demais, analisando o erro percentual em previsões anuais do modelo e foi o modelo escolhido. Para previsões (não acumuladas) de curto, médio e longo prazo o modelo BVAR é o que apresenta melhor precisão, como podemos constatar pela análise da tabela 4.3.2.4.

Tabela 4.3.2.4 - Habilidade Preditiva do ICMS.

Série	ERRO ANUAL DO MODELO MULTIVARIADO			ERRO ANUAL DO MODELO UNIVARIADO (%) ¹
	BVAR (%)	BVEC (%)	VEC (%)	
ICMS	4.63	4.55	4.84	4.41

Passos à frente	Num. Obs.	THEIL-U –ICMS			
		BVAR	BVEC	VEC	UNIVARIADO
1	33	0.56	0.56	0.57	0.713
2	32	0.62	0.64	0.65	0.694
3	31	0.57	0.60	0.61	0.681
4	30	0.59	0.64	0.66	0.708
5	29	0.66	0.69	0.72	0.686
6	28	0.62	0.64	0.65	0.665
7	27	0.67	0.67	0.69	0.768
8	26	0.76	0.75	0.78	0.775
9	25	0.79	0.79	0.81	0.715
10	24	0.81	0.8	0.79	0.784
11	23	0.9	0.94	1.03	0.840
12	22	0.98	1.05	1.11	0.912

Nota: :¹ O modelo univariado encontra-se em destaque, pois apresentou melhor resultado.

Fonte: Elaborada pelos próprios autores.

IPI

Com base na estatística-t, as variáveis explicativas que apresentaram melhor nível de significância para o modelo multivariado foram: População (RJ), IBC, Taxa de Câmbio e Consumo de Energia (BR).

A habilidade preditiva do modelo univariado apresentou melhor resultado em previsões anuais. Porém, entre os modelos multivariados, o modelo VEC se mostrou melhor que os demais analisando o erro percentual em previsões anuais do modelo e foi o modelo escolhido. Para previsões de curto, médio e longo prazo (não acumuladas) o modelo BVAR é o que apresenta melhor precisão, em geral, entre os multivariados, como podemos constatar pela análise da tabela 4.3.2.5.

Tabela 4.3.2.5 - Habilidade Preditiva do IPI.

Série	ERRO ANUAL DO MODELO MULTIVARIADO			ERRO ANUAL DO MODELO UNIVARIADO (%) ¹
	BVAR (%)	BVEC (%)	VEC (%)	
IPI	7.69	7.51	7.47	5.89

Tabela 4.3.2.5 - Habilidade Preditiva do IPI.

(Continuação)

Passos à frente	Num. Obs.	THEIL-U -IPI			
		BVAR	BVEC	VEC	UNIVARIADO
1	33	0.76	0.78	0.78	0.834
2	32	0.8	0.78	0.78	0.832
3	31	0.69	0.69	0.69	0.682
4	30	0.77	0.8	0.8	0.783
5	29	0.79	0.83	0.84	0.744
6	28	0.92	0.97	0.97	0.855
7	27	0.86	0.88	0.87	0.771
8	26	0.94	0.97	0.97	0.816
9	25	0.82	0.83	0.83	0.738
10	24	0.97	0.96	0.96	0.882
11	23	0.85	0.82	0.82	0.725
12	22	0.82	0.85	0.85	0.700

Nota: : ¹ O modelo univariado encontra-se em destaque, pois apresentou melhor resultado.

Fonte: Elaborada pelos próprios autores.

IPVA

Com base na estatística-t, as variáveis explicativas que apresentaram melhor nível de significância para o modelo multivariado foram: População (RJ), Consumo de Combustível (RJ) e Crédito de Automóvel (BR).

A habilidade preditiva do modelo univariado apresentou melhor resultado em previsões anuais. Porém, entre os modelos multivariados, o modelo BVEC se mostrou melhor que os demais, tanto analisando o erro percentual em previsões anuais como a estatística Theil-U. O BVEC foi o modelo multivariado escolhido, e as estatísticas de habilidade preditiva encontram-se na tabela 4.3.2.6.

Tabela 4.3.2.6 - Habilidade Preditiva do IPVA.

Série	ERRO ANUAL DO MODELO MULTIVARIADO			ERRO ANUAL DO MODELO UNIVARIADO (%) ¹
	BVAR (%)	BVEC (%)	VEC (%)	
IPVA	6.77	4.82	4.83	2.67

Passos à frente	Num. Obs.	THEIL-U -IPVA			
		BVAR	BVEC	VEC	UNIVARIADO
1	33	0.38	0.36	0.36	0.160
2	32	0.24	0.2	0.2	0.101
3	31	0.19	0.18	0.18	0.097
4	30	0.18	0.16	0.16	0.092
5	29	0.18	0.16	0.16	0.091
6	28	0.18	0.16	0.16	0.092
7	27	0.18	0.16	0.17	0.092
8	26	0.17	0.15	0.15	0.097
9	25	0.18	0.17	0.17	0.103
10	24	0.2	0.18	0.18	0.125
11	23	0.28	0.27	0.26	0.172
12	22	1.59	1.46	1.47	0.998

Nota: : ¹ O modelo univariado encontra-se em destaque, pois apresentou melhor resultado.

Fonte: Elaborada pelos próprios autores.

IRRF

Com base na estatística-t, as variáveis explicativas que apresentaram melhor nível de significância para o modelo multivariado foram: População (RJ), Produção Industrial (RJ) e Emprego Formal (RJ).

A habilidade preditiva do modelo univariados em previsões anuais apresentou melhor resultado. Porém, entre os modelos multivariados, o modelo BVAR se mostrou o melhor analisando o erro percentual em previsões anuais e o Theil-U. O BVAR foi o modelo multivariado escolhido, como podemos constatar pela análise da tabela 4.3.2.7.

Tabela 4.3.2.7 - Habilidade Preditiva do IRRF.

Série	ERRO ANUAL DO MODELO MULTIVARIADO			ERRO ANUAL DO MODELO UNIVARIADO (%)
	BVAR (%)	BVEC (%)	VEC (%)	
IRRF	22.35	23.65	23.66	7.71

Passos à fronted	Num. Obs.	THEIL-U –IRRF			
		BVAR	BVEC	VEC	UNIVARIADO
1	33	0.66	0.67	0.67	0.610
2	32	0.61	0.62	0.59	0.570
3	31	0.62	0.63	0.59	0.563
4	30	0.67	0.69	0.66	0.570
5	29	0.64	0.67	0.64	0.505
6	28	0.65	0.68	0.66	0.604
7	27	0.64	0.65	0.65	0.563
8	26	0.66	0.66	0.65	0.582
9	25	0.57	0.59	0.58	0.492
10	24	0.64	0.63	0.64	0.542
11	23	0.56	0.6	0.58	0.472
12	22	0.76	0.87	0.82	0.553
24	10	0.39	0.65	0.49	0.309

Fonte: Elaborada pelos próprios autores.

ITCMD

Com base na estatística-t, as variáveis explicativas que apresentaram melhor nível de significância para o modelo multivariado foram: População (RJ), Capacidade Instalada (RJ) e Crédito Imobiliário (BR).

A habilidade preditiva do modelo VEC se mostrou melhor que a dos demais analisando o erro percentual em previsões anuais. O modelo VEC foi o modelo escolhido. Para previsões de curto e longo prazos (não acumuladas) o modelo BVEC é o que apresenta melhor precisão, como podemos constatar pela análise da tabela 4.3.2.8.

Tabela 4.3.2.8 - Habilidade Preditiva do ITCMD.

Série	ERRO ANUAL DO MODELO MULTIVARIADO			ERRO ANUAL DO MODELO UNIVARIADO (%)
	BVAR (%)	BVEC (%)	VEC (%)	
ITCMD	16.61	10.84	10.73	12.99

Tabela 4.3.2.8 - Habilidade Preditiva do ITCMD.

(Continuação)

Passos à frente	Num. Obs.	THEIL-U -ITCMD			
		BVAR	BVEC	VEC	UNIVARIADO
1	33	0.74	0.71	0.71	0.745
2	32	0.68	0.63	0.63	0.633
3	31	0.69	0.64	0.65	0.653
4	30	0.74	0.69	0.69	0.710
5	29	0.72	0.68	0.68	0.696
6	28	0.68	0.66	0.64	0.663
7	27	0.79	0.77	0.74	0.762
8	26	0.96	0.93	0.89	0.921
9	25	0.46	0.39	0.4	0.667
10	24	0.38	0.3	0.33	0.391
11	23	0.4	0.3	0.33	0.326
12	22	0.47	0.36	0.39	0.373

Fonte: Elaborada pelos próprios autores.

Salário Educação

Com base na estatística-t, as variáveis explicativas que apresentaram melhor nível de significância para o modelo multivariado foram: População (RJ) e Massa Salarial (RJ).

A habilidade preditiva do modelo BVEC se mostrou melhor do que as demais analisando o erro percentual em previsões anuais. O BVEC foi o modelo escolhido. Para previsões de curto, médio e longo prazo o modelo BVEC é o modelo multivariado que apresenta melhor precisão, como podemos constatar pela análise da tabela 4.3.2.9. O modelo univariado prevê melhor do que todos os modelos no curto e médio prazos.

Tabela 4.3.2.9 - Habilidade Preditiva do Salário Educação.

Série	ERRO ANUAL DO MODELO MULTIVARIADO			ERRO ANUAL DO MODELO UNIVARIADO (%)
	BVAR (%)	BVEC (%)	VEC (%)	
SE	8.29	1.54	3.34	3.86

Passos à frente	Num. Obs.	THEIL-U –SalárioEducação			
		BVAR	BVEC	VEC	UNIVARIADO
1	33	0.28	0.26	0.36	0.236
2	32	0.28	0.24	0.25	0.225
3	31	0.3	0.26	0.29	0.269
4	30	0.36	0.3	0.33	0.309
5	29	0.35	0.26	0.29	0.259
6	28	0.36	0.26	0.28	0.250
7	27	0.41	0.28	0.29	0.251
8	26	0.44	0.29	0.33	0.306
9	25	0.39	0.25	0.28	0.270
10	24	0.41	0.26	0.28	0.280
11	23	0.43	0.26	0.27	0.286
12	22	1.18	0.72	0.74	0.734

Fonte: Elaborada pelos próprios autores.

SUS

Com base na estatística-t, as variáveis explicativas que apresentaram melhor nível de significância para o modelo multivariado foram: População (RJ), IBC e Internação (RJ).

A habilidade preditiva do modelo BVEC se mostrou melhor do que os demais analisando o erro percentual em previsões anuais e o Theil-U. O modelo BVEC foi o modelo escolhido, como podemos constatar pela análise da tabela 4.3.2.10. O modelo univariado é melhor nas previsões de curto prazo. O modelo univariado é melhor nas previsões de curto prazo, até dois passos à frente.

Tabela 4.3.2.10 - Habilidade Preditiva do SUS.

Série	ERRO ANUAL DO MODELO MULTIVARIADO			ERRO ANUAL DO MODELO UNIVARIADO (%)
	BVAR (%)	BVEC (%)	VEC (%)	
SUS	27.97	11.08	17.33	14.49

Passos à frente	Num. Obs.	THEIL-U –SUS			
		BVAR	BVEC	VEC	UNIVARIADO
1	33	0.96	0.76	0.88	0.693
2	32	0.97	0.86	0.92	0.845
3	31	0.94	0.82	0.89	0.889
4	30	0.97	0.84	0.92	0.858
5	29	1.65	1.34	1.42	1.561
6	28	0.94	0.83	0.95	0.899
7	27	1	0.85	0.92	0.926
8	26	1.12	0.95	1.02	0.987
9	25	1.11	0.96	1.04	0.979
10	24	1.34	1.14	1.2	1.203
11	23	1.14	0.96	1.06	1.015
12	22	0.99	0.85	0.94	0.905

Fonte: Elaborada pelos próprios autores.

5. CONCLUSÕES

Estimamos modelos univariados e multivariados para várias receitas da SEFAZ (Secretaria da Fazenda) do estado do Rio de Janeiro. Para todas as variáveis de receita chegamos a modelos com razoável capacidade preditiva. Para algumas variáveis as previsões dos modelos multivariados superaram as dos modelos univariados, o que é em geral um resultado difícil de obter.

REFERÊNCIAS BIBLIOGRÁFICAS

- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. (1994). *Time Series Analysis, Forecasting and Control*. 3 ed. Englewood Cliffs, NJ: Prentice-Hall, Inc., 1994.
- GEWEKE, J. "Antithetic acceleration of Monte Carlo Integration in Bayesian Inference". *Journal of Econometrics*, v. 38(1), p. 73-89, 1988.
- GOOIJER, Jan G. De; HYNDMAN, Rob J. 25 years of time series forecasting. *International Journal of Forecasting*, v. 22(4), p. 443-473, 2006.
- HARVEY, A. C.; TODD, P.H.J. "Forecasting economic time series with structural and Box-Jenkins models: a case study" (with

- discussion), *Journal of Business and Economic Statistics*, v. 1, p. 299-315, 1983.
- JOHANSEN, S. "Statistical Analysis of Cointegrating Vectors". *Journal of Economic Dynamics and Control*, v. 12, p. 231-254, 1988.
- KLING, J. L.; BESSLER, D. A. "A comparison of multivariate forecasting procedures for economic time series". *International Journal of Forecasting*, v. 1, P. 5-24, 1985.
- LITTERMAN, R.B. "A Bayesian Procedure for Forecasting with Vector Autoregressions". *Mimeo. Massachusetts Institute of Technology*, 1980.
- LITTERMAN, R.B. Forecasting with Bayesian Vector Autoregressions – Five years of Experience, *Journal of Business & Economic Statistics*, v. 4, p. 25-38, 1986.
- KADIYALA, K.; KARLSSON, S. "Numerical methods for estimation; inference in Bayesian VAR-models". *Journal of Applied Econometrics*, v. 12, p. 99-132, 1987.
- TEXTER, P. A.; ORD, J. K. "Forecasting using automatic identification procedures: a comparative analysis". *International Journal of Forecasting*, v. 5, p. 209-215, 1989.
- WANG, Z.; BESSLER, D. A. "Forecasting performance of multivariate time series models with a full and reduced rank: an empirical examination". *International Journal of Forecasting*, v. 20, p. 683-695, 2004.