DOI: *http://dx.doi.org/10.1590/0101-416145497cpf*

Robustez de regressões de crescimento frente à incerteza sobre a especificação do modelo: quão robustos são os regressores para o caso brasileiro? ♦

Christiano Penna
Professor – Universidade Federal do Ceará (UFC)
Endereço: Avenida da Universidade, 2700 - 2º Andar Benfica – Fortaleza/CE – Brasil
CEP 60020-181 – E-mail: cmp@caen.ufc.br

Fabricio Linhares
Professor – Universidade Federal do Ceará (UFC)
Endereço: Avenida da Universidade, 2700 - 2º Andar Benfica – Fortaleza/CE – Brasil
CEP 60020-181 – E-mail: flinhares@caen.ufc.br

Recebido em 27 de março de 2014. Aceito em 19 de maio de 2015.

Resumo

Embora haja uma vasta literatura que busca identificar regressores robustos capazes de influenciar o crescimento econômico em âmbito internacional, esse tema ainda carece de pesquisas que apresentem resultados estatisticamente satisfatórios para o caso brasileiro. O presente artigo busca contribuir para a identificação de variáveis robustas capazes de influenciar o crescimento econômico brasileiro. A base de dados de Resende e Figueiredo (2010) é reexaminada e busca-se contornar o problema da incerteza com relação à especificação do modelo. Para tanto, utilizou-se a técnica de Ponderação de Modelos Frequentista proposta em Hansen e Racine (2012), conhecida por *Jackknife Model Averaging.* Essa técnica não é tão restritiva quanto a *Extreme Bound Analysis* e nem tão permissiva quanto a abordagem de Sala-i-Martin (1997). Os resultados da pesquisa sugerem que, dentre os 22 regressores investigados, apenas a carga tributária global teria influência significante sobre o crescimento. Em linhas gerais, nossos resultados permanecem indicando muita cautela ao se trabalhar com regressões de crescimento que fazem uso de dados estaduais. Outrossim, o trabalho motiva estudos futuros e chama a atenção para a importância de se retomar essa linha de pesquisa.

Palavras-Chave

Regressões de crescimento. Ponderação de modelos. Jackknife Model Averaging.

Abstract

Although there is a vast literature that seeks to identify robust regressors able to influence economic growth at the international level, this issue still needs research that have satisfactory results for the Brazilian case. This article aims to contribute to the identification of robust variables that influence the Brazilian economic growth. The Resende and Figueiredo (2010) dataset is reviewed and we seek to circumvent the problem of uncertainty about the model specification. For this purpose, a Frequentist Model Averaging technique proposed in Hansen and Racine (2012) is used. This method is known

♦ Os autores agradecem ao CNPq pelo financiamento da pesquisa através do Edital MCTI / CNPq/MEC/CAPES N º 07/2011.

by Jackknife Model Averaging and it is not as restrictive as the Extreme Bound Analysis and not as permissive as the approach of Sala-i-Martin (1997). The results suggest that, among the 22 investigated covariates, only the overall tax burden would have significant influence on growth. In general, our results remain indicating caution when working with growth regressions that use state data. Moreover, the work motivates further studies and draws attention to the importance of resuming this line of research.

Keywords
Growth regressions. Model averaging. Jackknife Model Averaging.

JEL Classification
O47. O38. O21.

1. Introdução

O estudo de Barro e Sala-i-Martin (1992) formalizou a ideia de que o processo de convergência de renda das economias poderia ser empiricamente testado através de uma simples regressão *cross-section* da taxa média de crescimento contra a renda *per capita* inicial. Os autores atentaram ainda para a possibilidade de que as rendas *per capita* das economias convergiriam para posições de estado estacionário diferenciadas, dado que as economias possuíam características estruturais distintas e, com o intuito de controlar esse resultado, propuseram o acréscimo de outras variáveis explicativas no modelo de regressão, tais como taxa de crescimento populacional, taxa de depreciação e taxa de progresso tecnológico.

Nesse esteio, Mankin, Romer e Weil (1992) sugeriram que a taxa de acumulação de capital humano seria uma das variáveis capazes de influenciar o processo de convergência de um grupo de economias para posições de estado estacionário distintas. Os autores incluíram os anos de estudo como variável de controle e as regressões desse tipo passaram a ser conhecidas na literatura por “regressões de Solow aumentadas”, ou “regressões de crescimento”.

Embora a literatura empírica inicial tenha feito vasto uso de regressões deste tipo, as mesmas podem estar mal especificadas, pois não se sabe ao certo quais variáveis estariam de fato influenciando o processo de crescimento das economias. Durlauf e Quah (1999), por exemplo, listam um total de 87 variáveis “potencialmente explicativas” sugeridas na literatura. A atualização desta análise em Durlauf, Johnson e Temple (2005) afirma que este número já havia subido para 145. A primeira proposta de se identificar variáveis apropriadas para se incluir nas regressões de crescimento se deve à Levine e Renelt (1992). O estudo empregou a análise de limites extremos (EBA)[1] proposta por Leamer (1983, 1985) e concluiu que o único candidato robusto seria a participação do investimento no PIB. Talvez por questionar a validade das análises empíricas feitas com base em regressões de crescimento, este estudo passou a sofrer diversas críticas e, a partir delas, alguns aprimoramentos foram propostos.

Uma das principais críticas é a de que uma série de modelos teóricos seria capaz de explicar o processo de crescimento. Assim, se um modelo econométrico for associado a cada um destes modelos teóricos, e posto que tais modelagens não sejam mutuamente exclusivas, viria à tona uma incerteza em relação a que variáveis tivessem que ser incluídas para que se capturasse o verdadeiro processo gerador de dados. Com base nessa crítica, Minier (2007) refez o trabalho de Levine e Renelt (1992), permitindo que a regressão de crescimento assumisse um caráter não linear compatível com um efeito *threshold*, assim como especificações de termos cruzados e quadráticos entre variáveis. A autora encontra que, se estas potenciais não linearidades são levadas em conta, então diversos indicadores de política fiscal (medidas de gastos do governo, impostos e déficit orçamentário) estariam fortemente correlacionados com o crescimento.

Sala-i-Martin (1997) propôs uma variante mais flexível da análise de limites extremos, em que se estipulava níveis de confiança para o efeito de cada variável. Estes níveis de confiança eram obtidos a partir de um processo de ponderação das funções de verossimilhança de todos os possíveis modelos e, por conseguinte, de todas as estimativas de seus parâmetros e de seus respectivos desvios-padrão. A análise de Sala-i-Martin, entretanto, ainda parecia carecer de apelo teórico e metodológico.

Antes destes dois estudos, a análise do efeito de variáveis que possivelmente viriam a influenciar o crescimento econômico era feita em dois estágios: no primeiro estágio selecionava-se subjetivamente um modelo “apropriado” e, no segundo, se fazia inferência a partir deste modelo, como se o mesmo fosse o modelo estatístico que melhor se ajustava aos dados. Entretanto, ao se indicar subjetivamente um

[1] *EBA – Extreme Bondary Analisys.*

modelo como apropriado no primeiro estágio, o pesquisador passava a incorrer num viés, pois ele ignorava prontamente toda a incerteza com relação aos demais modelos que poderiam ser propostos. Além disso, se a equação empírica apresentar regressores supérfluos, os estimadores seriam não viesados, mas sua variância pode vir a ser afetada; se apresenta regressores de menos, ou seja, se a mesma omite informação relevante, então o viés nos estimadores se faz presente. Este viés vem do fato de que, se o modelo estabelecido subjetivamente não for o mais adequado à estrutura dos dados, então o mesmo tende a subestimar a variância dos estimadores, sobrepujando, assim, os intervalos de confiança associados ao mesmo, o que traria, consequentemente, inferências equivocadas a partir deste modelo.[2]

Esse aspecto metodológico era o que faltava na análise de Sala-i-Martin e, com base nele, uma série de estudos sucedeu-se, buscando averiguar de que forma se poderia chegar a uma regressão de crescimento robusta que permitisse identificar quais variáveis seriam realmente capazes de influenciar a taxa de crescimento das economias. Houve duas maneiras de se lidar com isto: a abordagem "do geral para o específico" (*GETS*)[3] e a metodologia de ponderação de modelos, ou *Model Averaging*.

Uma excelente revisão de literatura que trata da modelagem *GETS* pode ser encontrada em Campos, Ericsson e Hendry (2005). Dentro da área de crescimento econômico, a investigação empírica através da *GETS* pode ser vista nos trabalhos de Hoover e Perez (2004) e Hendry e Krolzig (2004). Hoover e Perez (1999, 2004) sugerem que a seleção do modelo de regressão *cross-country* de crescimento deva ser feita através do algoritmo *GETS* proposto por eles em 1999. Os autores conduzem simulações utilizando um subconjunto de dados aproveitados no estudo de regressões *cross-coutry* de Levine e Renelt (1992), e reafirmam que talrdagemrmam que o modelo discuss abordagem é demasiadamente rigorosa, enquanto que a metodologia de

2 Como notado em Nunes (2006), o excesso de variáveis a serem incluídas no modelo pode trazer o problema de multicolinearidade, ou seja, algumas das variáveis podem ser altamente correlacionadas. A multicolinearidade faz com que algumas das variáveis sejam irrelevantes para a explicação do fenômeno em estudo e, além disso, a inclusão destas variáveis num modelo aumenta a variância dos estimadores de mínimos quadrados de seus coeficientes de regressão (Rao, 1971). Por outro lado, a omissão de variáveis importantes introduz viés de especificação e o modelo pode tornar-se subparametrizado. Do ponto de vista prático, tanto modelos sub quanto superparametrizados trazem consigo inferências equivocadas, o que compromete qualquer tipo de análise.

3 *GETS – General to Specific Model.*

Sala-i-Martin (1997) seria muito permissiva. Utilizando simulações de Monte Carlo, os autores identificam que algumas variáveis políticas, tais como liberdade civil, direitos políticos, organização econômica e abertura ao comércio, são particularmente importantes para o crescimento. As variáveis "Estado de Direito", "Revoluções e Golpes de Estado", assim como "Guerras", também sobressaem na seleção de regressores do modelo geral para o específico. Variáveis que refletem as condições macroeconômicas e financeiras, que foram indicadas como não robustas pela análise dos limites extremos, são relativamente importantes na especificação *GETS*. Hendry e Krolzig (2004), por sua vez, identificaram os determinantes do crescimento econômico através de uma estratégia de seleção *GETS* disponibilizada nos pacotes computacionais *PcGETS* e *PcGive* (ver Hendry e Doornick, 2001). Os autores refazem a análise de Hoover e Perez (2004), assim como refazem a análise Bayesiana de Fernandez *et al.* (2001). Os algoritmos sugerem variáveis relevantes e irrelevantes através do teste da significância das variáveis individuais e agrupadas, e testam a especificação correta dos modelos resultantes. Ao analisar todas as estratégias de redução possíveis, tal estratégia assegura que os resultados do modelo final, o qual é estimado via MQO, não depende da exclusão inicial das variáveis insignificantes. Com efeito, os resultados da análise são muito próximos da análise de Hover e Perez (2004), mas destoam da análise de Fernandez *et al.* (2001).

Em resumo, a análise *GETS* parece estar em consonância com o experimento de Monte Carlo realizado pelos autores, e retorna algumas mensagens: a primeira é a de que as condições iniciais são relevantes para a análise. "Fatores Religiosos" e o "Nível Inicial de Desenvolvimento Econômico", que, infelizmente, não são passíveis de políticas públicas, são relativamente importantes. As "Dotações Iniciais de Recursos", "Fatores Religiosos e Geográficos", a "Expectativa de Vida Inicial" e o "Nível Inicial de Desenvolvimento Econômico" também são variáveis que se mostraram relevantes para o processo de crescimento econômico. Outra mensagem importante é a de que, embora um elevado investimento privado, um ambiente macroeconômico estável e a ausência de guerras sejam capazes de prescrever, na melhor das hipóteses, uma maior taxa de crescimento econômico, os fatores que mais afetam as diferenças de taxas de crescimento seriam aqueles que estão fora do controle dos formuladores de políticas.

A modelagem *GETS* envolve um procedimento para seleção do modelo que tipicamente se delineia com base na significância estatística dos parâmetros através das suas razões t. Magnus (1999) aponta uma série de problemas com respeito a esta técnica. A crítica mais importante - conhecida na literatura como "*pretesting*" - é a de que a seleção do modelo é completamente desvinculada do procedimento de estimação, o que geraria estimativas condicionais, e não estimativas incondicionais. Outra crítica é que a abordagem *GETS* permite basicamente que se trabalhe com modelos aninhados, ou seja, com modelos que são casos especiais de um modelo mais abrangente.[4]

Uma alternativa que combina seleção de modelo e estimação é chamada de Ponderação de Modelos, ou *Model Averaging*. Através dessa técnica, a incerteza diante da escolha de um modelo é contornada com base na ponderação de todos os modelos propostos, ou na ponderação dos melhores modelos indicados por algum critério. Esta abordagem surgiu na década de sessenta, e vem sendo bastante utilizada na área de crescimento econômico. Tal metodologia é costumeiramente desmembrada em duas linhas de pesquisa: a Bayesiana e a Frequentista, que, embora similares em espírito e objetivos, são visivelmente distintas em termos de inferência e de ponderação dos modelos.

A metodologia de Ponderação de Modelos Bayesiana (*BMA*) trata a incerteza na especificação do modelo através da atribuição de *priors* a cada um dos potenciais modelos.[5] A distribuição dos coeficientes associados às variáveis de interesse são médias das distribuições das estimativas dos vários modelos em consideração, ponderados

4 A ideia de modelos aninhados e não aninhados tem relação com a especificação do modelo no que concerne às variáveis capazes de influenciá-lo. Considere os três modelos a seguir, supondo que as variáveis dispostas em X são diferentes das de Z:

i) $Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \beta_3 X_{3i} + u_i$

ii) $Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + e_i$

iii) $Y_i = \alpha_0 + \alpha_1 Z_{1i} + \alpha_2 Z_{2i} + v_i$

Os modelos (i) e (ii) são ditos aninhados, pois o modelo (ii) pode ser entendido como um caso especial do modelo primeiro com $\beta_3 = 0$. Já os modelos (ii) e (iii) são ditos não aninhados, pois não se pode definir um deles como um caso especial do outro.

5 Em probabilidade bayesiana, uma distribuição de probabilidade *a priori* para uma quantidade indeterminada *p*, também chamada simplesmente de ***prior*** relativo a *p* é a distribuição de probabilidade que expressaria a incerteza sobre o valor de *p* antes de qualquer *dado* ou medida. É uma maneira de atribuir incerteza em vez de aleatoriedade à grandeza em questão, além de ponto de partida para o uso do teorema de Bayes após a obtenção dos dados.

por suas respectivas probabilidades a *posteriori* calculadas através do método de estimação Bayesiano. Por sua vez, a Ponderação de Modelos Frequentista (*FMA*) vem tradicionalmente lidando com a questão da incerteza, dando um maior foco ao cálculo das ponderações atribuídas a todos os possíveis modelos. Para tanto, utilizam-se de procedimentos de otimização que buscam o melhor ajustamento ou desempenho preditivo do modelo ponderado. Em contraste à vertente Bayesiana, a abordagem Frequentista não requer *priors*, e suas estimativas são exclusivamente determinadas pelos dados.

Hjort e Claeskens (2003) apontam alguns inconvenientes para a abordagem *BMA* como, por exemplo, a maneira subjetiva que se atribui probabilidades a *priori* [ver Hoeting *et al.* (1999) para uma discussão detalhada deste problema] e como lidar com *priors* quando os mesmos entram em conflito uns com os outros. Moral-Benito (2012) aponta dois sérios problemas adicionais em relação à implementação do *BMA*: (i) é necessário estabelecer dois tipos de *priors* (para os parâmetros e para os modelos) para diversos modelos candidatos, o que pode ser uma tarefa bastante complexa e, (ii) o número de modelos candidatos geralmente é bastante amplo e a implementação de cálculos computacionais do *BMA* pode se tornar proibitiva em casos onde há muitas variáveis candidatas, embora isso também possa ocorrer no caso Frequentista. Talvez por conta disso, a abordagem Frequentista passou a receber uma maior atenção e contribuições ao longo da última década. Dentro desta abordagem, a literatura destaca alguns estimadores, cujas principais diferenças residem na forma como os pesos no processo de estimação são estabelecidos. Há, por exemplo, a escolha de pesos baseada em critérios de informação (Buckland, Burnham e Augustin, 1997), a escolha de pesos baseada no critério de Mallows (Hansen, 2007), a escolha de pesos baseada no estimador não viesado do risco (Liang, Zou e Zhang, 2009), e a escolha de pesos baseada no critério da validação cruzada, ou *Jackknife Model Averaging* (Hansen e Racine, 2012).

Dado que diferentes pesos resultam em diferentes riscos e propriedades assintóticas, é importante utilizar um critério apropriado para cada análise. Dentre os diferentes critérios para seleção de pesos citados, o *Jackknife Model Averaging* (*JMA*) é um dos que chama bastante a atenção. Hansen e Racine (2012) propuseram recentemente uma maneira de selecionar pesos que, se comparada ao critério de Mallows, é mais apropriada para modelos lineares, pois permite que os erros aleatórios tenham, inclusive, variância heterocedástica, além de se permitir que os modelos sejam não aninhados. Assintoticamente, esse estimador atinge o menor erro quadrático médio (EQM) quando comparado aos seus concorrentes.

Zhang, Wan e Zou (2013) ampliam o escopo da análise de Hansen e Racine (2012), permitindo que se incluam modelos com correlação serial e variáveis dependentes defasadas, permitindo, assim, dependência nos dados. Os autores demonstram que o estimador *JMA* ainda é assintoticamente ótimo quando embasado nessas hipóteses. Os autores ainda conduzem um experimento de Monte Carlo para analisar o desempenho em amostras finitas do estimador *JMA* frente a estimadores frequentistas e critérios de ponderação de modelos alternativos. Para todas as configurações, o *JMA* se mostrou favorito com relação à minimização do erro quadrático médio.

No campo aplicado, embora exista uma vasta literatura internacional que lida com a incerteza acerca de quais variáveis seriam capazes de influenciar o processo de crescimento econômico, especificamente para o caso brasileiro, nossa revisão de literatura identificou apenas o estudo de Resende e Figueiredo (2010), que investigaram quais variáveis (de 30 variáveis sugeridas em referenciais empíricos e teóricos) possuiriam uma correlação mais significativa com as taxas de crescimento do PIB *per capita* dos estados brasileiros. Estes autores utilizaram as metodologias proposta por Levine e Renelt (1992), e o enfoque alternativo proposto por Sala-i-Martin (1997), concluindo que,

> *"... de acordo com o teste EBA, nenhuma variável é robusta. Entretanto, ao se usar o teste em que toda a distribuição dos coeficientes é analisada, chega-se à conclusão de que migração contribui positivamente para o crescimento do PIB per capita dos estados; enquanto urbanização, taxa de mortalidade infantil, fecundidade, pluviometria e carga tributária (elevada ao quadrado) estão correlacionadas negativamente com as taxas de crescimento do PIB per capita dos estados brasileiros. Além disso, confirma-se a ocorrência de convergência condicional dos PIBs per capita dos estados."*
> Resende e Figueiredo (2010)

Os resultados dessa pesquisa inicial sugerem a existência de uma enorme barreira no Brasil em termos de políticas públicas. Esta barreira decorre do fato de que, sendo o governo incerto em relação às quais variáveis são realmente capazes de influenciar o processo de crescimento econômico, então toda a eficiência e eficácia de políticas públicas pró-crescimento poderia ser questionada.

A principal contribuição deste artigo é a retomada de uma linha de pesquisa que ainda não trouxe resultados satisfatórios para o campo do crescimento econômico brasileiro, mas que foi deixada de lado de modo aparentemente prematuro.[6] Na tentativa de se investigar a existência de regressores robustos para o caso brasileiro, aqui se empregou a técnica do *Jackknife Model Averaging*, a qual tem a vantagem de ser menos permissiva que a abordagem de Sala-i-Martin (1997), mas não tão restritiva quanto a abordagem de Levine e Renelt (1992). Buscando uma congruência com a análise realizada anteriormente, o estudo aqui conduzido explora a base de dados de Resende e Figueiredo (2010).[7] De um modo geral, assim como sustenta a análise de Resende e Figueiredo (2010), nossos resultados permanecem sugerindo que os regressores estaduais utilizados em regressões de crescimento são frágeis. Ainda assim, acrescenta-se ao final do artigo que este resultado está longe de ser um consenso, e sugere-se uma série de pontos que podem ser seguidos com o intuito de se trazer resultados mais palatáveis para o caso brasileiro.

A pesquisa está dividida da seguinte forma: após esta introdução, a abordagem de Ponderação de Modelos Frequentista (*FMA*) com foco no critério de Validação Cruzada (*JMA*) é discutido. A terceira seção apresenta os dados e aspectos metodológicos da pesquisa empírica; a seção 4 apresenta os resultados e a quinta seção conclui.

[6] Note-se que Resende e Figueiredo (2010) é uma publicação de um Texto de Discussão do IPEA findado em 2005, o qual sugere que os regressores analisados são frágeis. Com efeito, há 10 anos não se realizam estudos empíricos para o Brasil com o intuito de se investigar o quão robustas são as variáveis utilizadas nas regressões de crescimento.

[7] Gostaríamos de agradecer aos autores pela pronta disponibilização dos dados.

2. Jackknife Model Averaging

A aplicação da abordagem *FMA* tem data anterior ao trabalho de combinação de Bates e Granger (1969) na área de previsão, e o trabalho de Claeskens e Hjort (2003) apresenta uma série de ilustrações empíricas que fazem uso dessa técnica. A presente seção se concentra em realizar uma revisão da teoria e de alguns dos principais métodos ligados à abordagem *FMA*, seguindo, principalmente, a exposição de Wang, Zhang e Zou (2009). Para facilitar a exposição, iremos apresentar um modelo linear básico e ilustrar a definição de estimador *FMA*, sendo que a extensão para modelos mais gerais pode ser feita sem maiores problemas. Considere o seguinte modelo linear:

$$y = X\beta + Z\gamma + \varepsilon \qquad (1)$$

onde $y(n \times 1)$ é um vetor de variáveis dependentes, $X(n \times p)$ e $Z(n \times q)$ são matrizes de regressores não aleatórios, $\beta(p \times 1)$ e $\gamma(q \times 1)$ são vetores de parâmetros e, $\varepsilon(n \times 1)$ é um vetor de erros aleatórios. Aqui se está assumindo que *(X, Z)* tem posto cheio (p+q) e que *X* possui as variáveis que necessariamente devem ser incluídas no modelo, enquanto Z contém variáveis candidatas ou que potencialmente podem ser incluídas (ou não) no modelo.

Para facilitar a explanação metodológica, suponha $p = 1$ e $q = 2$. Nestes termos, ter-se-iam quatro modelos candidatos:

i) $y_i = \beta_1 x_{1i} + \gamma_1 z_{1i} + \gamma_2 z_{2i} + \varepsilon_i$

ii) $y_i = \beta_1 x_{1i} + \gamma_1 z_{1i} + \varepsilon_i$

iii) $y_i = \beta_1 x_{1i} + \gamma_2 z_{2i} + \varepsilon_i$

iv) $y_i = \beta_1 x_{1i} + \varepsilon_i$

Generalizando, se teria um total de $K = 2^q$ modelos candidatos. Seja $\hat{\beta}_k$ o estimador de β para o modelo k, onde $k = 1, \dots, K$;[8] A análise de dados usual toma um determinado modelo selecionado como verdadeiro, por exemplo, o modelo τ, e reporta apenas a

[8] Note-se que os k modelos candidatos têm como parâmetros a serem estimados β_1^k, γ_1^k e γ_2^k para $k = 1, 2, 3, 4$.

variância ou erro quadrático médio de , enquanto o estimador apropriado deveria ser dado por:

$$\hat{\beta} = \begin{cases} \hat{\beta}_1 \,, & \text{se o modelo candidato 1 for selecionado} \\ \vdots & \\ \hat{\beta}_K \,, & \text{se o modelo candidato } K \text{ for selecionado} \end{cases}$$

Por simplicidade, o estimador acima pode ser notado por

$$\hat{\beta} = \sum_k \bar{\lambda} \hat{\beta}_k \tag{2}$$

onde $\bar{\lambda} = 1$, se k o modelo candidato for selecionado e, $\bar{\lambda} = 0$, caso contrário. Note-se que, neste caso, os pesos são determinados com base nos dados e que nenhum tipo de conhecimento a *priori* é requerido, o que diferencia substancialmente esta abordagem da *BMA*.

O estimador descrito em (2) é chamado estimador pré-teste, pois ele não passou por nenhum tipo de teste que levasse em consideração a incerteza acerca do modelo. Um problema com esta classe de estimadores é que, devido à $\bar{\lambda}$ ser binária, $\hat{\beta}$ passa a reunir uma série de propriedades indesejáveis como, por exemplo, viés.[9] Para se contornar esse problema, pode-se trabalhar com o que se chama de "pesos suavizados" ao invés dos pesos com a estrutura de $\bar{\lambda}$. Neste caso, pode-se utilizar a seguinte notação para o estimador de modelos ponderados:

$$\hat{\beta} = \sum_k \hat{\lambda} \hat{\beta}_k \tag{3}$$

onde $0 \leq \hat{\lambda} \leq 1$ e $\sum_k \hat{\lambda} = 1$. Note-se que, ao contrário dos *priors* do *BMA*, $\hat{\lambda}$ é parte integrante da seleção do modelo e do procedimento de estimação e, por isso, passa a ser entendido como um estimador *FMA* de β.

Wang, Zhang e Zou (2009) discorrem sobre algumas maneiras de se selecionar $\hat{\lambda}$ em (3). Há, na literatura, a escolha de pesos baseada em critérios de informação (Buckland, Burnham e Augustin, 1997), a escolha de pesos baseada no critério de Mallows (Hansen, 2007),

[9] Ver Judge e Bock (1978) para uma discussão detalhada sobre estimadores pré-teste.

a escolha de pesos baseada no estimador não viesado do risco (Liang, Zou e Zhang, 2009), e a escolha de pesos baseada no critério da validação cruzada, ou *Jackknife Model Averaging* (Hansen e Racine, 2012).

Dado que diferentes pesos resultam em diferentes riscos e diferentes propriedades assintóticas para $\hat{\beta}$, é importante utilizar um critério apropriado para cada análise. Hansen e Racine (2012) propõem que se selecionem os pesos do estimador de modelos ponderados via MQO, através da minimização de um critério de validação cruzada excludente, o qual foi chamado pelos autores de *Jackknife* Model Averaging (*JMA*). Esta técnica é mais apropriada para modelos lineares mais gerais, para modelos os quais erros aleatórios possuam variância heterocedástica, assim como para ponderação de modelos não aninhados (Hansen e Racine, 2012).

Hansen e Racine (2012) ainda demonstram que o estimador proposto é assintoticamente ótimo no sentido de alcançar o menor erro quadrático médio possível. As Simulações de Monte Carlo dos autores revelam ainda que o *JMA* pode conseguir ganhos de eficiência significativos frente aos outros métodos na presença de heterocedasticidade. Wang, Zhang e Zou (2013) trabalham dependência nos dados via regressores defasados e uma matriz de erros mais geral, que permite também correlação serial. Os autores mostram através de um experimento de Monte Carlo que, em amostras finitas, o *JMA* é ótimo frente a outros critérios de ponderação de modelos quando se compara o EQM dos estimadores. Com efeito, dentre os diferentes critérios para seleção de pesos citados, o *Jackknife Model Averaging* (*JMA*) é um dos que chama bastante a atenção.

Para se apresentar o estimador *Jackknife* compatível com (3), tome (1) e forme:

$$y_i = (X, Z)\begin{pmatrix}\beta \\ \gamma\end{pmatrix} + \varepsilon_i = \mu(x_i) + \varepsilon_i \tag{1'}$$

ou seja,

$$y_i = \mu_i + e_i, \, E(e_i \mid x_i) = 0 \tag{4}$$

onde, (y_i, x_i) é uma amostra de observações independentes para $i=1, \ldots, n$, e $\mu_i = \mu(x_i) = E(y_i \mid x_i)$ é defina como sendo a média condicional. Seja $\boldsymbol{y} = (y_1, \dots, y_n)'$, $\mu = (\mu_1, \dots, \mu_n)'$ e $\boldsymbol{e} = (e_1, \dots, e_n)'$. Definindo também a variância condicional por $\sigma_i^2 = E(e_i^2 \mid x_i)$, a qual pode depender de x_i, ou seja, notando-se que há espaço para heterocedasticidade.[10] Suponha que se tem um conjunto de estimadores lineares $\{\hat{\mu}^1, \hat{\mu}^2, \dots, \hat{\mu}^K\}$ para μ. Por linear se admite que o *k-ésimo* estimador pode ser descrito como $\hat{\mu}^k = \boldsymbol{P}_k \boldsymbol{y}$, onde $\boldsymbol{P}_k$ não é uma função de $\boldsymbol{y}$.

No caso de estimadores de mínimos quadrados, tem-se $\boldsymbol{P}_k = \boldsymbol{X}^k(\boldsymbol{X}^{k\prime}\boldsymbol{X}^k)^{-1}\boldsymbol{X}^{k\prime}$, onde a *i-ésima* linha de $\boldsymbol{X}^k$ é x_i^k, uma função de $m_k \times 1$ de x_i. Um estimador, ou modelo, corresponde a um conjunto de regressores x_i^k em particular, e se permite que a matriz de regressores seja aninhada ou não aninhada.[11] Em geral, o potencial conjunto de regressores x_i é grande e os regressores x_i^k são subconjuntos de x_i.

O problema de se selecionar um modelo concerne em selecionar um estimador do conjunto $\{\hat{\mu}^1, \hat{\mu}^2, \dots, \hat{\mu}^K\}$ Note-se que, o estimador ótimo de mínimos quadrados não é necessariamente o maior modelo (ou modelo mais completo). Ao se utilizar o erro quadrático médio como critério de avaliação de modelos, por exemplo, a minimização desse critério pode ser atingida através da ponderação de estimadores. Seja $\boldsymbol{\lambda} = (\lambda^1, \lambda^2, \dots, \lambda^K)'$ um conjunto de pesos que soma 1, então, dado $\boldsymbol{\lambda}$, um estimador ponderado para μ toma a forma:

$$\hat{\mu}(\boldsymbol{\lambda}) = \sum_{k=1}^{K} \lambda^k \hat{\mu}^k = \hat{\mu}\boldsymbol{\lambda} = \boldsymbol{P}(\boldsymbol{\lambda})\boldsymbol{y} \tag{5}$$

onde $\hat{\mu} = (\hat{\mu}^1, \hat{\mu}^2, \dots, \hat{\mu}^K)'$ é a matriz n x K de estimativas $\boldsymbol{P}(\boldsymbol{\lambda}) = \sum_k \lambda^k \boldsymbol{P}_k$ e é um operador linear indexado por $\boldsymbol{\lambda}$, o que sugere que, para pesos fixos, o estimador ponderado $\hat{\mu}(\boldsymbol{\lambda})$ é linear em $\boldsymbol{y}$ e também é linear nos pesos $\boldsymbol{\lambda}$.

Ao definir os pesos $\boldsymbol{\lambda}$ de modo que os mesmos sejam vetores unitários l_k, tais que, $\lambda^k = 1$ e $\lambda^l = 0$ se $l \neq k$, o estimador ponderado simplifica a seleção do estimador $\hat{\mu}^k$. Permitindo pesos não unitários, generaliza-se a seleção de estimadores e se obtém funções

[10] Zhang, Wan e Zou (2013) permitem que a matriz de variância e covariância dos erros suporte tanto heterocedasticidade quanto autocorrelação.

[11] No caso da matriz de regressores ser aninhada ter-se-á $span(\boldsymbol{X}^k) \subset span(\boldsymbol{X}^{k+1})$. Em outros casos a matriz de regressores pode ser não aninhada.

suaves dos dados. Hansen (2007) demonstra que o estimador ponderado descrito acima atinge o menor erro quadrático médio quando comparado a qualquer outro estimador individual.

No caso de regressões lineares aninhadas, é necessário que os pesos sejam não negativos, estando dentro do simplex unitário, $H_n = \left\{ \lambda \in \Re^K : \lambda^k \geq 0, \sum_{k=1}^{K} \lambda^k = 1 \right\}$. Ademais, no contexto de regressões não paramétricas em série com regressores ortogonais, a ordem em que se dispõem os regressores passa a ser extremamente importante, tanto para a seleção do modelo, quanto para a seleção dos estimadores.

Hansen e Racine (2012) definem o *k-ésimo* estimador *Jackknife* por $\tilde{\mu}^k = \left(\tilde{\mu}_1^k, \tilde{\mu}_2^k, \ldots, \tilde{\mu}_n^k\right)'$, onde $\tilde{\mu}_i^k$ é o estimador $\hat{\mu}_i^k$ computado com a *i-ésima* observação deletada. Assim, pode-se escrever $\tilde{\mu}_i^K = \widetilde{\boldsymbol{P}}_k \boldsymbol{y}$, onde $\widetilde{\boldsymbol{P}}_k$ tem zeros em sua diagonal. O vetor de resíduos *Jackknife* para o *k-ésimo* estimador é $\tilde{\boldsymbol{e}}^{\boldsymbol{k}} = \boldsymbol{y} - \tilde{\mu}^k$. Note-se que, no caso de mínimos quadrados, teremos $\tilde{\mu}_i^k = x_i^{k'} \left(\boldsymbol{X}_{(-i)}^k{}' \boldsymbol{X}_{(-i)}^k\right)^{-1} \boldsymbol{X}_{(-i)}^k{}' \boldsymbol{y}_{(-i)}$, onde $\boldsymbol{X}_{(-i)}^k$ e $\boldsymbol{y}_{(-i)}$ denotam as matrizes $\boldsymbol{X}^k$ e $\boldsymbol{y}$, com a *i-ésima* linha deletada. Isso sugere que $\widetilde{\boldsymbol{P}}_k = \boldsymbol{D}_k(\boldsymbol{P}_k - \boldsymbol{I}) + \boldsymbol{I}$, onde, $\boldsymbol{D}_k$ é uma matriz diagonal de ordem com o *i-ésimo* elemento da diagonal igual a $\left(1 - h_{ii}^k\right)^{-1}$, onde $h_{ii}^k = x_i^{k'} \left(\boldsymbol{X}^{\boldsymbol{k}'} \boldsymbol{X}^{\boldsymbol{k}}\right)^{-1} x_i^k$ é o *i-ésimo* elemento da diagonal de $\boldsymbol{P}_k$.

Segue-se que o vetor de resíduos *Jackknife* pode ser escrito como $\tilde{\boldsymbol{e}}^k = \boldsymbol{D}_k \hat{\boldsymbol{e}}^k$, onde $\hat{\boldsymbol{e}}^k = \boldsymbol{y} - \boldsymbol{P}_k \boldsymbol{y}$ é o vetor de resíduos de mínimos quadrados. Note-se que, usando tal representação, $\tilde{\boldsymbol{e}}^k$ pode ser computado com uma simples operação linear, e não requer n regressões separadas.

A versão *Jackknife* do estimador ponderado passa a ser:

$$\tilde{\mu}(\boldsymbol{\lambda}) = \sum_{k=1}^{K} \lambda^k \tilde{\mu}^k = \tilde{\mu}\boldsymbol{\lambda} = \widetilde{\boldsymbol{P}}(\boldsymbol{\lambda})\boldsymbol{y} \tag{6}$$

onde $\tilde{\mu} = (\tilde{\mu}^1, \tilde{\mu}^2, \ldots, \tilde{\mu}^K)$, $\widetilde{\boldsymbol{P}}(\boldsymbol{\lambda}) = \sum_{k=1}^{K} \lambda^k \widetilde{\boldsymbol{P}}_k$, $\widetilde{\boldsymbol{P}}(\boldsymbol{\lambda})$, e notando-se que a matriz $\widetilde{\boldsymbol{P}}(\boldsymbol{\lambda})$ tem zeros em sua diagonal.

Os resíduos ponderados pelo *Jackknife* são descritos por: $\tilde{e}(\boldsymbol{\lambda}) = y - \tilde{\mu}(\boldsymbol{\lambda}) = \sum_{k=1}^{K} \lambda^k \tilde{e}^k = \tilde{\boldsymbol{e}}\boldsymbol{\lambda}$, onde $\tilde{e} = (\tilde{e}^1, \tilde{e}^2, \ldots, \tilde{e}^K)$, A estimativa de *Jackknife* para o verdadeiro erro quadrático médio esperado será dada por $CV_n(\lambda) = \frac{1}{n}\tilde{\boldsymbol{e}}(\boldsymbol{\lambda})'\tilde{\boldsymbol{e}}(\boldsymbol{\lambda}) = \boldsymbol{\lambda}'\boldsymbol{S}_n\,\boldsymbol{\lambda}$, onde $\boldsymbol{S}_n = \frac{1}{n}\tilde{\boldsymbol{e}}'\tilde{\boldsymbol{e}}$ é uma matriz $K \times K$. $CV_n(\boldsymbol{\lambda})$ também é conhecido como critério de validação cruzada para mínimos quadrados.

A escolha de pesos *Jackknife* (de validação cruzada) é o valor que minimiza $CV_n(\boldsymbol{\lambda})$ em $\boldsymbol{\lambda} \in H_n$,[12] ou seja, $\hat{\boldsymbol{\lambda}} = \arg\min_{\boldsymbol{\lambda}\in H_n} CV_n(\boldsymbol{\lambda})$. Assim sendo, o estimador do modelo ponderado de *Jackknife* de μ é dado por $\hat{\mu}(\hat{\boldsymbol{\lambda}}) = \hat{\mu}\hat{\boldsymbol{\lambda}}$.

Ao se considerar vetores de pesos unitários, l_k, então $CV_n(l_k)$, então é o critério *Jackknife* padrão para seleção dos modelos de regressão, e o seu minimizador, $\hat{l}_k$, é o modelo (*Jackknife*) padrão selecionado. Assim sendo, o estimador *JMA* $\hat{\mu}(\hat{\boldsymbol{\lambda}})$ é uma generalização da seleção do modelo *Jackknife*. Ademais, ele é uma função mais suave dos dados, pois a seleção discreta dos modelos individuais cede lugar à seleção suave de pesos entre os modelos.

Algebricamente, o problema $\hat{\boldsymbol{\lambda}} = \arg\min_{\boldsymbol{\lambda}\in H_n} CV_n(\boldsymbol{\lambda})$ é um problema de mínimos quadrados restrito. O vetor $\hat{\boldsymbol{\lambda}}$ é um vetor de coeficientes de ordem K X 1 obtido através da regressão restrita de $\boldsymbol{y}$ em $\widetilde{\mu}$, a qual possui ordem n X K. Vale lembrar que os parâmetros de $\widetilde{\mu}$ seguem distribuição t de Student padrão [ver Tukey (1987)]. A regressão descrita pode ser convenientemente escrita como $\boldsymbol{y} = \tilde{\mu}\boldsymbol{\lambda} + \tilde{\boldsymbol{e}}$; nestes termos, o vetor de pesos de *Jackknife* $\hat{\boldsymbol{\lambda}}$ são os pesos condizentes com uma combinação linear dos diferentes estimadores que retornam o menor erro quadrático.

Buckland, Burnham e Augustin (1997) revelam que a fórmula para a variância do estimador *JMA* apresenta viés, pois se teria:

$$VAR\left[\hat{\mu}(\hat{\boldsymbol{\lambda}})_v\right] = \left\{\sum_{k=1}^{K} \lambda^k \sqrt{VAR(\hat{\mu}^k|v^k) + (v^k)^2}\right\}^2 \tag{7}$$

[12] Em teoria, se teria um subconjunto de H_n, entretanto, na prática, pode-se trabalhar H_n utilizando-se algoritmos que tratem de programação quadrática sem maiores problemas. Ver Hansen e Racine (2012) para uma discussão detalhada.

Onde, o subscrito v em $VAR\left[\hat{\mu}(\hat{\boldsymbol{\lambda}})_v\right]$ indica a presença de viés de especificação, de tamanho v^k, o qual advém da hipótese de se estimar $\hat{\mu}$ sob hipótese de que o verdadeiro modelo seria o k-ésimo candidato. Burnham e Anderson (2002), no entanto, sugerem que esta variância pode ser estimada ao se substituir $VAR(\hat{\mu}^k|v^k)$ e v^k por seus valores estimados, ou seja, fazendo:

$$\widehat{Var[\hat{\mu}(\lambda)]} = \left\{\sum_{k=1}^{K} \lambda^k \sqrt{\widehat{Var}(\hat{\mu}^k|v^k) + (\hat{\mu}^k - \hat{\mu}_v)^2}\right\}^2 \tag{8}$$

onde $v^k = \hat{\mu}^k - \hat{\mu}_v$ e $\hat{\mu}_v = \sum \lambda^k \hat{\mu}^k$.

Hjort e Claeskens (2003) revelam que esta técnica gera erros padrão mais precisos, os quais incluem a incerteza adicional devido à seleção do modelo.

3. Dados e aspectos metodológicos

No Brasil, são poucos os trabalhos que investigam a relevância das variáveis explicativas em regressões de crescimento econômico. Em verdade, afora o trabalho de Resende e Figueiredo (2010), não se consegue citar outro trabalho rigoroso do ponto de vista estatístico com esse intuito.

O referido trabalho tem como foco 30 possíveis regressores. A análise atenta da base de dados dos autores revela que diversas variáveis para o ano de 1960 foram criadas a partir de extrapolação. No estudo aqui conduzido optou-se por retirar tais variáveis da amostra, pois é de se esperar que a técnica de extrapolação empregada pelos autores possa gerar uma possível contaminação dos resultados. Buscando não se reduzir o número de regressores utilizados em nossa pesquisa, aqui se optou por eliminar a década de 60 da análise. Além disso, algumas variáveis também foram atualizadas. O presente trabalho analisa as seguintes variáveis, gentilmente cedidas por Resende e Figueiredo (2010):[13]

[13] Aqui se manteve o código das variáveis conforme o trabalho original. As estatísticas descritivas das variáveis aqui utilizadas são apresentadas no Apêndice. As mesmas não se alteram substancialmente quando comparadas às de Resende e Figueiredo (2010).

Tabela1 - Variáveis utilizadas

Código	Variável	Descrição
Variável Dependente	Taxa de crescimento do PIB per capita	Produto Interno Bruto (PIB) a preços constantes de 2000. Taxas anuais médias de crescimento para os períodos 1960/1970, 1970/1980, 1980/1990 e 1990/2000.
X1 e X2	Dummies de tempo	Dummies de tempo para as décadas de 1970 e 1980, respectivamente. X1 é um vetor de com 1's para a década de 1970 e X2 é um vetor de com 1's para a década de 1980
X4	Ln (PIB per capita)	Logaritmo neperiano do PIB a preços constantes. Unidade: R$ mil do ano 2000. PIB no início do período (1970, 1980 e 1990).
X5	Taxa de crescimento da população	Taxas anuais médias de crescimento para os períodos 1970/1980, 1980/1990 e 1990/2000.
X6	Participação do setor industrial no PIB	Parcela do PIB industrial estadual em relação ao PIB total de cada Estado. PIB no início do período (1970, 1980 e 1990).
X7	Participação do setor agropecuário no PIB	Parcela do PIB agropecuário estadual em relação ao PIB total de cada Estado. PIB no início do período (1970, 1980 e 1990).
X8	Participação do setor de comércio no PIB	Parcela do PIB do setor de comércio em relação ao PIB total de cada Estado. PIB no início do período (1970, 1980 e 1990).
X9	Participação do setor de serviços no PIB	Parcela do PIB do setor de serviços estadual em relação ao PIB total de cada Estado. PIB no início do período (1970, 1980 e 1990).
X10	Densidade populacional (Proxy para efeitos de congestão)	Densidade populacional = pop. Total de cada estado/área total do estado. Densidade populacional no início do perí-odo (1970, 1980 e 1990).
X11	Taxa de urbanização (Proxy para economias de aglomeração)	Taxa de urbanização = pop. Urbana estadual/pop. Total estadual. Taxa de urbanização no início do período (1970, 1980 e 1990).
X14	Proxy 3 para capital humano	Número médio de anos de estudo das pessoas de 25 ou + anos de idade, no início do período (1970, 1980 e 1990). Unidade: Ano. Comentário: Razão entre o somatório do número de anos de estudo completos das pessoas nessa faixa etária e o total dessas pessoas.
X17	Taxa de mortalidade infan-til (Proxy1 para o estado de saúde)	Número de crianças que não irão sobreviver ao primeiro ano de vida em cada mil crianças nascidas vivas [início do período (1970, 1980 e 1990)]. Unidade: para mil nascidos vivos.
X19	Expectativa de vida (Proxy² para o estado de saúde)	Número de anos de vida que uma pessoa nascida hoje esperaria viver, se todas as taxas de mortalidade por idade se mantivessem idênticas ao que são hoje. Dado para o início das décadas (1970, 1980 e 1990).
X20	Temperatura	Temperaturas (ºC) médias das capitais para os períodos 1970/1980, 1980/1990 e 1990/2000.
X22	Índice pluviométrico	Altura total (mm) (soma dos doze meses) média (das capitais) para os períodos 1970/1980, 1980/1990 e 1990/2000.
X23	Consumo de energia elé-trica (Proxy para estoque de capital físico)	Consumo de energia elétrica (GWh) estadual no início de cada década (1970, 1980 e 1990).
X24	Proxy¹ para infraestrutura (Esgoto)	Porcentagem de domicílios com instalações sanitárias rede geral. Dado para o início das décadas (1970, 1980 e 1991).
X25	Proxy² para infraestrutura (Abastecimento de água)	Porcentagem de domicílios com água canalizada rede geral. Dado para o início das décadas (1970, 1980 e 1991).
X26	Proxy³ para infraestrutura (Iluminação elétrica)	Porcentagem de domicílios com iluminação elétrica. Dado para o início das décadas (1970, 1980 e 1991).
X27	Proxy para desigualdade na distribuição de renda (Índice L de Theil)	Índice L de Theil. Comentário: Mede a desigualdade na distribuição de indivíduos segundo a renda domiciliar per capita. É o logaritmo da razão entre as médias aritmé-tica e geométrica das rendas individuais, sendo nulo quando não existir desigualdade de renda entre os indivíduos e tendente ao infinito quando a desigualdade tender ao máximo. Para seu cálculo, excluem-se do universo os indivíduos com renda domiciliar per capita nula. Dado para o início das dé-cadas (1970, 1980 e 1991).
X28	Carga tributária global	A carga tributária global é calculada baseada na arrecadação tributária real média do triênio centrada nos anos censitários em relação ao PIB desses anos. É o somatório da arre-cadação federal, estadual e municipal em cada estado da Feder-ação. Unidade: %. Dado para o início das décadas (1970 1980 e 1990).
X29	(Carga tributária global)²	A carga tributária global elevada ao quadrado é calculada baseada na arrecadação tributária real média do triênio centrada nos anos censitários em relação ao PIB desses anos. Unidade: %. Dado para o início das décadas (1970, 1980 e 1990).

Nossa estratégia empírica consiste em duas análises. A primeira análise é condizente com teste *EBA* conduzido por Resende e Figueiredo (2010). No referido teste, os autores fixam as *dummies* de tempo (***X1*** e ***X2***), o crescimento populacional (***X5***) e taxa de matrícula no ensino primário (***X12***) e utilizam no teste todas as possíveis combinações de três regressores adicionais. Aqui, seguimos a estratégia dos autores fixando as *dummies* de tempo e o crescimento populacional; a variável taxa de matrícula no ensino primário foi substituída pelo número médio de anos de estudo das pessoas de 25 anos ou mais de idade (***X14***), também fixa, e fixou-se, adicionalmente, o logaritmo neperiano da renda *per capita* inicial (***X4***).[14] Os resultados dessa análise podem ser vistos na Tabela 2, na próxima seção.

A segunda análise é mais flexível no tratamento das variáveis que não são fixas. O que se faz é permitir que as variáveis disponíveis sejam combinadas de maneiras diversas: como não se sabe ao certo de que maneira tais variáveis devem realmente ser combinadas, essa segunda análise envolveu combinações de 4 regressores fixos (optou-se por deixar as *dummies* de tempo como regressores auxiliares, ou seja, fixou-se apenas o termo constante e as variáveis ***X4***, ***X5*** e ***X14***) e estimou-se modelos com 4 regressores fixos e com 3 a 5 regressores auxiliares, e com 4 regressores fixos e com 14 a 18 regressores variáveis.[15] Com o intuito de se refinar a análise, também utilizaram-se os erros-padrão propostos por Burnham e Anderson (2002). As estimativas geradas são apresentadas na próxima seção, onde são discutidos os resultados.

4. Resultados

Inicialmente emprega-se a metodologia proposta em Hansen e Racine (2012) aos dados citados na seção anterior. O primeiro ensaio busca uma aproximação da estratégia empírica de Resende e Figueiredo (2010), e mantém como regressores fixos o termo cons-

[14] Note-se que a variável taxa de matrícula no ensino primário foi extrapolada para o ano de 1960, razão pela qual optou-se por não se trabalhar com tal proxy para capital humano e variável logaritmo neperiano da renda *per capita* inicial tem grande apelo teórico quanto empírico, *vide* os diversos modelos advindos do modelo de Solow (1956) e os estudos empíricos que seguiram a abordagem seminal de Mankiw, Romer e Weil (1992).

[15] A estimação de outras possíveis combinações não foi realizada devido ao custo computacional (8 GB de memória não são suficientes), tendo em vista a complexidade da técnica empregada.

tante, as *dummies* de tempo (***X1*** e ***X2***), o logaritmo neperiano da renda *per capita* inicial (***X4***), o crescimento populacional (***X5***) e o número médio de anos de estudo das pessoas de 25 anos ou mais de idade (***X14***). Os resultados são os que se seguem:

Tabela 2 – Ensaio 1

Variável	Descrição	Estimativa	Erro Padrão
CTE	*Termo constante*	*1,339279*	*17,989915*
*X4**	*Ln Renda Inicial*	*-0,92006*	*1,110501*
X5	*Crescimento Populacional*	*-0,1131*	*0,364233*
X14	*Anos médios de Estudo*	*0,485364*	*0,597657*
X1	*Dummy de tempo*	*6,888978*	*7,350939*
X2	*Dummy de tempo*	*0,241432*	*0,809687*
X6	*Participação da Indústria*	*0,021788*	*0,642821*
X7	*Participação da Agropecuária*	*-0,36273*	*1,299584*
X8	*Participação do Comércio*	*3,543720*	*66.032557*
X9	*Participação dos Serviços*	*0,467923*	*3,698895*
X10	**Densidade Populacional**	**-0,00107**	**0,000548**
*X11**	*Taxa de Urbanização*	*-0,74265*	*2.982.318*
X17*	**Taxa de Mortalidade Infantil**	**-0,00153**	**0,001021**
X19	*Expectativa de Vida*	*0,010969*	*0,010528*
X20	*Temperatura*	*-0,01484*	*0,014751*
X22*	**Índice Pluviométrico**	**-0,00019**	**0,000099**
X23	*Cons. Energia Elétrica*	*-0.000004*	*0,000006*
X24	*Esgoto*	*-0,00248*	*0,003396*
X25	*Abastecimento de água*	*-0,00491*	*0,007189*
X26	*Iluminação Elétrica*	*-0,00264*	*0,003551*
X27	*L de Theil*	*0,462695*	*1,653945*
X28	*Carga Tributária*	*-0,00977*	*0,016543*
X29*	**Carga Tributária 2**	**-0,00062**	**0,000311**

Fonte: Elaboração dos autores.
Nota: X* indica robustez do regressor no estudo de Resende e Figueiredo (2010);
Nota: Parâmetro estatisticamente significativo ao **nível de 5%** e ao **nível de 10%.**

Embora os resultados aqui apresentados não sejam diretamente comparados com os de Resende e Figueiredo (2010), torna-se interessante confrontar os mesmos. Naquele estudo todas as variáveis se revelaram frágeis de acordo com o teste *EBA*, enquanto as variáveis (***X4***) *Nível do PIB per capita no início do período; (**X11**) Taxa de urbanização; (**X17**) Taxa de mortalidade infantil; (**X18**) Taxa de fecundidade; (**X22**) Índice pluviométrico; (**X29**) Carga tributária global ao quadrado; e, (**X30**) Taxa líquida de migração*, seriam variáveis ditas robustas segundo a metodologia de Sala-i-Martin (1997).

Embora a amostra aqui utilizada seja relativamente reduzida se comparada à daquele estudo, a técnica aqui empregada, por sua vez, sustenta que a Taxa de Urbanização e a Taxa de mortalidade infantil não seriam relevantes para explicar o crescimento econômico brasileiro. Também é interessante contrastar o valor dos coeficientes estimados do estudo aqui conduzido com o estudo realizado anteriormente. Isso é feito a seguir:

Tabela 3 – Comparação dos coeficientes significativos

Variável	Descrição	JMA	Resende e Figueiredo
X4*	Ln Renda Inicial	-0,92006	-1,476
X10	Densidade Populacional	-0,00107	-0,007
X11*	Taxa de Urbanização	-0,74265	-5,814
X17*	Taxa de Mortalidade Infantil	-0,00153	-0,018
X22*	Índice Pluviométrico	-0,00019	-0,0014
X29*	Carga Tributária[2]	-0,00062	-0,0038

Fonte: Elaboração dos autores.

* Estatisticamente significantes em Resende e Figueiredo.

Ao comparar o valor dos coeficientes estimados aqui e no estudo de Resende e Figueiredo (2010) se observa que todos os coeficientes têm o mesmo sinal, entretanto, as magnitudes dos coeficientes estimados através da técnica de *Jackknife Model Averaging* são inferiores *à*s dos estimados através do teste de Sala-i-Martin (1997), ou seja, os coeficientes no estudo de Resende e Figueiredo poderiam ter sido sobrestimados. Com o intuito de se averiguar a robustez desses resultados, permitiu-se que as variáveis disponíveis fossem combinadas de diversas maneiras distintas. A Tabela 4, a seguir, expõe os resultados para combinações de 4 regressores fixos - fixando-se apenas o ***Termo constante*** e as variáveis ***X4***, ***X5*** e ***X14*** - e estimou-se modelos com 3, 4, 5, 14 15, 16, 17 e 18 regressores auxiliares. Um número de regressores auxiliares, que não estes, elevam demasiadamente o custo computacional para se estimar os parâmetros do modelo.

Diversas questões interessantes são observadas a partir deste ensaio: nota-se que a ***Dummy referente à década de 70*** (***X1***) só é estatisticamente significante (ao nível de 5%) com um número relativamente pequeno de regressores auxiliares; ao se incluir mais do que três regressores variáveis a *dummy* perde significância estatística e só retoma esta significância (ao nível de 10%) ao se incluir um número muito grande de regressores auxiliares (18).

Também se constata que o único regressor mantido como fixo que apresenta significância estatística requer um número muito grande de regressores auxiliares para isso: A ***Taxa de crescimento populacional*** (***X5***) tem valor positivo e é estatisticamente significante ao nível de 10% quando se tem 16 regressores variáveis e, ao nível de 5%, quando se especificam modelos com 17 ou 18 regressores auxiliares. A ***Densidade populacional*** (***X10***) só é estatisticamente significante ao nível de 10% para especificações que envolvem 18 regressores variáveis e, ainda assim, possui um efeito marginal muito reduzido.

Uma variável que chama a atenção é a ***Expectativa de vida*** (***X19***), a qual possui valor negativo, ou seja, contrário ao esperado, e estatisticamente significante ao nível de 10% para modelos com 3, 4 ou 5 regressores variáveis. A variável ***Temperatura média das capitais*** (***X20***), por sua vez, possui valor condizente com diversos estudos empíricos e só não é estatisticamente significante, para um nível de 10%, na especificação com 16 regressores variáveis. O coeficiente negativo estimado para o ***Índice pluviométrico*** (***X22***) também é condizente com o esperado, embora só seja estatisticamente significante ao nível de 5% para modelos com 3 regressores livres e ao nível de 10% para modelos com 14 ou 15 regressores livres.[16]

A proxy para infraestrutura, ***Energia elétrica*** (***X26***) tem sinal contrário ao esperado, e só tem significância estatística para especificações com 3 regressores variáveis (5% de significância) ou 4 regressores variáveis (10% de significância). A variável que chama mais atenção nos resultados encontrados refere-se à ***Carga tributária global*** (***X28***), assim como o quadrado desta variável (***X29***). O efeito da carga tributária demonstrou-se positivo e estatisticamente significativo ao nível de confiança de 5% para todas as combinações testadas, o que deveria sugerir que, quanto maior a carga tributária, maior deve ser o crescimento econômico. Note-se, no entanto, que para especificações com um grande número de variáveis auxiliares (acima de 14), o coeficiente da ***Carga tributária ao quadrado*** (***X29***) é negativo e estatisticamente significante, sugerindo que o efeito da taxação sobre o crescimento tende a atingir um ápice e depois declinar.

[16] Ver Masters e McMillan (2001), por exemplo, para uma discussão sobre o efeito de fatores climáticos sobre o crescimento econômico.

Tabela 4 – Ensaio 2

	RF =4, RV=3		RF =4, RV=4		RF =4, RV=5		RF =4, RV=14		RF =4, RV=15		RF =4, RV=16		RF =4, RV=17		RF =4, RV=18	
	Estimativa	Erro Padrão	Estimativa	Erro Padrão	Estimativa	Erro Padrão	Estimativa	Erro Padrão	Estimativa	Erro Padrão	Estimativa	Erro Padrão	Estimativa	Erro Padrão	Estimativa	Erro Padrão
CTE*	8,963	216,743	9,964	284,333	11,034	327,239	2,582	53,398	1,025	35,167	0,919	31,818	1,644	29,795	-1,260	10,492
X4*	-2,687	7,376	-2,263	7,686	-2,003	7,816	-1,295	2,360	-1,284	2,019	-1,308	2,124	-1,731	1,690	-1,714	1,577
X5*	0,639	0,616	0,570	0,595	0,543	0,601	0,632	0,550	0,670	0,515	**0,743**	**0,547**	0,987	0,482	1,045	0,489
X14*	0,332	1,533	0,455	1,908	0,451	1,906	0,418	0,854	0,407	0,850	0,346	0,856	0,346	0,764	0,101	0,834
X1	0,671	0,395	**1,436**	**1,017**	1,618	1,247	4,719	4,254	5,232	4,731	4,794	4,463	5,664	4,394	**5,730**	**4,119**
X2	-0,322	1,720	-0,541	2,565	-0,732	3,405	-0,148	2,042	0,067	1,753	-0,090	2,309	0,491	1,373	0,464	1,420
X6	-0,565	7,522	-0,623	8,151	-0,651	9,645	1,275	15,872	1,534	16,417	2,000	17,289	-0,294	14,242	0,517	7,916
X7	-0,201	11,772	-0,466	13,219	-0,892	17,505	-4,736	28,351	-4,894	26,784	-4,987	24,096	-7,747	32,459	-7,813	23,153
X8	9,558	600,153	11,901	727,693	12,064	693,153	9,777	326,393	6,847	220,055	8,285	280,533	2,128	22,230	1,075	15,565
X9	0,164	7,893	0,957	16,361	1,237	17,088	5,160	20,535	6,517	20,874	7,189	21,431	6,098	22,747	7,878	27,061
X10	0,000	0,001	0,000	0,001	0,000	0,002	-0,002	0,004	-0,003	0,005	-0,003	0,006	0,000	0,000	**0,000**	**0,000**
X11	-0,552	5,773	-1,280	8,463	-1,690	11,164	-4,712	13,308	-5,462	13,368	-5,385	14,121	-8,121	10,628	-7,027	16,548
X17	-0,001	0,001	-0,001	0,002	-0,001	0,003	0,000	0,007	0,001	0,008	0,001	0,009	0,000	0,010	0,001	0,010
X19	**-0,039**	**0,029**	**-0,061**	**0,042**	**-0,068**	**0,050**	0,033	0,090	0,046	0,095	0,057	0,113	0,056	0,068	0,118	0,123
X20	**-0,095**	**0,062**	**-0,140**	**0,084**	**-0,159**	**0,095**	**-0,181**	**0,128**	**-0,185**	**0,134**	-0,215	0,166	**-0,223**	**0,145**	**-0,280**	**0,169**
X22	-0,001	0,000	0,000	0,000	0,000	0,000	**-0,001**	**0,000**	**-0,001**	**0,001**	-0,001	0,001	-0,001	0,001	-0,001	0,001
X23	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000
X24	0,002	0,005	0,000	0,008	-0,001	0,009	-0,009	0,018	-0,009	0,020	-0,009	0,022	-0,012	0,019	-0,012	0,027
X25	0,003	0,005	0,003	0,006	0,003	0,008	0,011	0,026	0,015	0,027	0,016	0,031	0,023	0,036	0,026	0,037
X26	-0,015	0,009	**-0,012**	**0,009**	-0,014	0,011	-0,009	0,032	-0,005	0,034	-0,008	0,038	0,009	0,041	0,002	0,045
X27	-1,648	18,793	-1,370	15,340	-1,309	14,249	-0,772	9,227	-0,626	8,814	-1,132	8,358	-0,049	3,978	-0,445	3,997
X28	0,120	0,062	0,089	0,050	0,098	0,056	0,354	0,144	0,397	0,153	0,421	0,159	0,633	0,217	0,642	0,219
X29	0,000	0,001	0,000	0,001	-0,001	0,001	-0,012	0,004	-0,014	0,004	-0,015	0,005	-0,022	0,006	-0,022	0,007

Fonte: Elaboração dos autores.

Nota: o Parâmetro estatisticamente significativo ao **nível de 5%** e ao **nível de 10%.**
RF se refere ao número de regressores fixos e RV se refere ao número de regressores variável.

5. Conclusões

No Brasil, a busca por identificação de causalidades, assim como a procura por políticas públicas que reduzam suas conhecidas desigualdades inter-regionais, tem instigado o desenvolvimento de diversos estudos baseados em regressões de crescimento; dentre os quais podem ser citados: Ferreira e Diniz (1995), Ellery e Ferreira (1996), Ferreira (1996, 1999, 2000), Zini Jr. (1998), Azzoni *et al.* (2000) e Resende e Figueiredo (2010).

O trabalho de Resende e Figueiredo (2010) chama a atenção por tratar diretamente de regressores robustos. Os autores sugerem que a renda *per capita* inicial, a urbanização, a mortalidade infantil, a fecundidade, a pluviometria, a carga tributária e a migração teriam uma correlação robusta com as taxas de crescimento do PIB *per capita* dos estados brasileiros ao se valer da abordagem de Sala-i-Martin (1997), mas, ao se utilizar o teste de robustez com base no *Extreme Boundary Analisys*, nenhum regressor seria robusto para a economia brasileira.

Os resultados encontrados em Resende e Figueiredo (2010) impõem um percalço aos formuladores de políticas públicas focadas no crescimento. É difícil crer que a educação, por exemplo, não seja capaz de contribuir para o crescimento econômico, principalmente ao se tratar do caso brasileiro; e é igualmente difícil encontrar argumentos teóricos ou empíricos capazes de refutar a educação como fator determinante para o crescimento. O que a análise de Resende e Figueiredo (2010) sugere, entretanto, é uma ruptura desta conexão. Aliás, a análise dos autores indica que pouquíssimas variáveis à disposição dos pesquisadores seriam, de fato, capazes de influenciar o processo de crescimento econômico brasileiro.

O rico conjunto de estudos internacionais, a importância do tema, e a incipiente literatura com enfoque no caso brasileiro, sugerem ser sensata a retomada de pesquisas que investiguem quais fatores seriam capazes de impulsionar o crescimento econômico do Brasil de um ponto de vista estatisticamente aceitável. Nesse esteio, o presente trabalho vem contribuir para esta discussão aplicando um teste de robustez com base na proposta de Hansen e Racine (2012). Essa técnica é conhecida por *Jackknife Model Averaging*, e é uma técnica de Ponderação de Modelos Frequentista (*FMA*) mais apropriada do que as metodologias propostas em Levine e Renelt (1992) e em Sala-i-Martin (1997).

Frente ao estudo inicial feito para o caso brasileiro, essa metodologia apresenta ainda uma série de vantagens, por exemplo: ela leva em consideração a incerteza com relação à especificação do modelo;[17] as regressões implementadas são mais abrangentes, no sentido de permitir a inclusão de um número bem maior de regressores auxiliares e contornar melhor a questão do viés de omissão de variáveis;[18] e são feitas várias imposições limitativas aos erros padrão e a distribuição das estimativas naquele estudo, enquanto aqui se tem algo muito menos restritivo.

Apesar das qualidades da nova técnica, a aplicação desta metodologia na base de dados de Resende e Figueiredo (2010) não traz grandes contribuições para os formuladores de políticas, pois a dificuldade de se encontrar variáveis que de fato sejam capazes de explicar o crescimento econômico permanece. Nossos resultados sugerem que o único regressor capaz de explicar o crescimento econômico brasileiro seria a carga tributária global, pois este seria o único regressor estatisticamente significante para todas as especificações propostas.

Vale notar que, segundo Helm (1995), apesar dos aumentos de impostos estaduais e locais retardarem significativamente o crescimento econômico ao serem utilizados para financiar transferências, ao se utilizar a receita desta tributação no financiamento da melhoria dos serviços públicos (como educação, rodovias, e saúde e segurança pública), observa-se um impacto favorável sobre a produção local capaz de compensar os efeitos de desincentivo dos impostos associados. Com efeito, embora não haja dados para o caso brasileiro que permitam uma análise mais profunda do que de fato ocorre, nossos resultados podem estar indicando que as receitas advindas da carga tributária global foram relativamente bem utilizadas durante o período investigado.

[17] Para se ter uma ideia, a análise de Sala-i-Martin (1997) aplicada aos nossos dados teria como base apenas $18 * C_3^{18} = 18 * \frac{18!}{(18-3)!\,3!} = 14.688$ regressões, já a análise aqui empregada requer que sejam estimados $2^{18} = 262.144$ modelos.

[18] A análise de Resende e Figueiredo atenta para a estimativa de uma variável na presença de 3 regressores auxiliares, enquanto que nossa análise permite até 18 regressores auxiliares.

De um modo geral, o resultado da pesquisa aqui conduzida reforça os achados iniciais de Resende e Figueiredo (2010) e sugerem que, em sua maioria, os regressores utilizados em regressões de crescimento seriam frágeis, ou seja, não seriam robustos. É importante ressaltar que, se por um lado, esse resultado questiona a eficácia e significância dos regressores utilizados em regressões de crescimento, por outro, ele procura retomar um ponto da agenda de pesquisa nacional, lançando luz sobre uma série de questões que poderiam vir a contribuir para nossa melhor compreensão do que de fato influencia o crescimento econômico brasileiro.

Apesar dos nossos resultados não serem muito animadores, é necessário observar que essa linha de pesquisa é bastante embrionária e que há três fatores limitam a análise: (i) a qualidade dos dados, (ii) a possibilidade de erros de especificação e, (iii) a ausência de testes de robustez alternativos.

Com relação à qualidade dos dados cabem adendos em torno de duas questões: A primeira refere-se à qualidade da própria base de dados aqui utilizada. A base de dados de Resende e Figueiredo (2010) é construída com base em dados decenais; essa é uma opção muito utilizada na literatura, pois evita o efeito de oscilações indesejáveis de curto prazo, entretanto, é possível que a redução dessa periodicidade torne-se mais apropriada às especificidades da economia brasileira. Também pode ser que bases de dados alternativas e mais abrangentes retornem resultados que permitam (alguma) inferência. A segunda questão refere-se à inexistência de dados para diversas variáveis importantes que deveriam ser incluídas no modelo empírico. Dados essenciais para a análise como, por exemplo, investimento em capital físico e investimento em capital humano, não se encontram disponíveis em âmbito estadual. Apesar do esforço em se utilizar aproximações para estas variáveis, não se sabe ao certo quão fidedignas são tais aproximações.

Essa inexistência de dados, *per se*, já induz o pesquisador a um erro de especificação, pois o mesmo é obrigado a partir de um modelo incorretamente especificado, o qual omite as variáveis relacionadas ao capital físico e humano, as quais são essenciais nas análises que sucederam o estudo seminal de Mankiw, Romer e Weil (1992). Também pode haver erros de especificação associados à forma funcional da regressão de crescimento: há na literatura diversos estudos mostrando uma não linearidade no processo de crescimento brasileiro;[19] ao incorporar tal questão ao estudo, também se abrem portas para resultados mais acurados. Também podem ser propostas especificações dinâmicas, com variáveis defasadas, mas seria necessário estudar qual seria a melhor forma de incorporar estas questões à metodologia aqui empregada.

O terceiro ponto refere-se à condução de testes de robustez possivelmente mais apropriados. Visto que a literatura empírica que trata do tema, em especial para o caso brasileiro, seja bastante incipiente, testes de robustez baseados em técnicas alternativas também podem vir a trazer resultados mais satisfatórios. A literatura com foco em *Model Averaging*, tanto Frequentista quanto Bayesiana, vem avançando continuamente, e pode ser que técnicas mais recentes se adaptem melhor à estrutura de dados disponíveis.

O estudo aqui delineado é um esforço de pesquisa que aponta, primeiramente, para que haja cautela ao se trabalhar com regressões de crescimento. As evidências empíricas apresentadas até o momento sugerem que os regressores disponíveis não são robustos para explicar o crescimento econômico dos estados brasileiros. Para que estudos futuros tragam consigo resultados mais palatáveis, é necessário que os órgãos de coleta e processamento de dados se empenhem constantemente na melhor mensuração das variáveis discutidas nos modelos de crescimento econômico. Sem medidas mais precisas de capital físico, capital humano, capital social, variáveis de geografia econômica e qualidades das instituições, dentre outras, torna-se difícil avançar na análise de quais fatores realmente seriam capazes de alavancar o crescimento econômico no Brasil. Obviamente, é de se esperar que, com o passar do tempo, o banco de dados enriqueça e possibilite melhores análises. Além disso, investir em novas técnicas de pesquisa também parece fundamental para que se deixe de encontrar resultados relativamente frágeis e se passe a propor políticas públicas aceitáveis de um ponto de vista estatístico.

---

[19] Ver Penna e Linhares (2013) para uma discussão detalhada deste processo.

Referências

AZZONI, C. et al. Geography and income convergence among Brazilian states. 2000.

BARRO, R. J.; SALA-I-MARTIN, X. Convergence. Journal of Political Economy, p. 223-251, 1992.

BATES, J. M.; GRANGER, C. WJ. The combination of forecasts. OR, p. 451-468, 1969.

BUCKLAND, S. T.; BURNHAM, K. P.; AUGUSTIN, N. H. Model selection: an integral part of inference. Biometrics, p. 603-618, 1997.

BURNHAM, K. P.; ANDERSON, D. R. Multimodel inference understanding AIC and BIC in model selection. Sociological Methods & Research, v. 33, n. 2, p. 261-304, 2004.

CAMPOS, J.; ERICSSON, N. R.; HENDRY, D. F. General-to-specific modeling: an overview and selected bibliography. 2005.

DURLAUF, S. N.; JOHNSON, P. A.; TEMPLE, J. RW. Growth econometrics. Handbook of Economic Growth, v. 1, p. 555-677, 2005.

DURLAUF, S. N.; QUAH, D. T. The new empirics of economic growth. Handbook of Macroeconomics, v. 1, p. 235-308, 1999.

ELLERY JR; FERREIRA, P. Convergência entre a renda per capita dos estados brasileiros. Revista de Econometria, v. 16, n. 1, p. 83-103, 1996.

FERNANDEZ, C.; LEY, E.; STEEL, M. FJ. Model uncertainty in cross-country growth regressions. Journal of Applied Econometrics, v. 16, n. 5, p. 563-576, 2001.

FERREIRA, A. Concentração regional e dispersão das rendas per capita estaduais: um comentário. Estudos Econômicos, v. 29, n. 1, p. 47-63, jan./mar. 1999. [Links]

_______. Convergence in Brazil: recent trends and long-run prospects. Applied Economics, 32, p. 479-489, 2000. [Links]

_______. Evolução recente da renda per capita estaduais no Brasil: o que a nova evidência mostra. Revista Econômica do Nordeste, v. 27, n. 3, p. 363-374, jul/set. 1996.

FERREIRA, A.; DINIZ, C. Convergência entre as rendas per capita estaduais no Brasil. Revista de Economia Política, v. 15, n. 4 (60), 1995.

HANSEN, B. E. Least squares model averaging. Econometrica, v. 75, n. 4, p. 1175-1189, 2007.

HANSEN, B. E.; RACINE, J. S. Jackknife model averaging. Journal of Econometrics, v. 167, n. 1, p. 38-46, 2012.

HELMS, L. Jay. The Effect of State and Local Taxes on Economic Growth: A Time Series--Cross Section Approach. The Review of Economics and Statistics, p. 574-582, 1985.

HENDRY, D. F.; DOORNIK, J. A. Empirical econometric modelling using PcGive 10. Timberlake Consultants, 2001.

HENDRY, D. F.; KROLZIG, Hans-Martin. We Ran One Regression*.Oxford bulletin of Economics and Statistics, v. 66, n. 5, p. 799-810, 2004.

HJORT, N. L.; CLAESKENS, G. Frequentist model average estimators. Journal of the American Statistical Association, v. 98, n. 464, p. 879-899, 2003.

HOETING, J. A. et al. Bayesian model averaging: a tutorial. Statistical science, p. 382-401, 1999.

HOOVER, K. D.; PEREZ, S. J. Truth and Robustness in Cross-country Growth Regressions*. Oxford Bulletin of Economics and Statistics, v. 66, n. 5, p. 765-798, 2004.

JUDGE, G. G.; BOCK, M. E. The Statistical Implications of Pre-Test and Stein-Rule Estimators in Econometrics. 1978.

KABAILA, P. On variable selection in linear regression. Econometric Theory, v. 18, n. 04, p. 913-925, 2002.

LEAMER, E. E. Sensitivity analyses would help. The American Economic Review, v. 75, n. 3, p. 308-313, 1985.

LEAMER, E.; LEONARD, H. Reporting the fragility of regression estimates. The Review of Economics and Statistics, v. 65, n. 2, p. 306-317, 1983.

LEVINE, R.; RENELT, D. A sensitivity analysis of cross-country growth regressions. The American Economic Review, p. 942-963, 1992.

MAGNUS, J. R. The traditional pretest estimator. Theory of Probability & Its Applications, v. 44, n. 2, p. 293-308, 2000.

MALLOWS, C. L. Some comments on C p. Technometrics, v. 15, n. 4, p. 661-675, 1973.

MANKIW, N. G.; ROMER, D.; WEIL, D. N. A contribution to the empirics of economic growth. The Quarterly Journal of Economics, v. 107, n. 2, p. 407-437, 1992.

MINIER, J. Nonlinearities and Robustness in Growth Regressions. The American Economic Review, v. 97, n. 2, p. 388-392, 2007.

MORAL-BENITO, E.; DE ESPANA, Banco. Model averaging in economics: An overview. Banco de España Working Paper, 2012.

PENNA, C.; LINHARES, F. Há controvérsia entre análises de beta e sigma-convergência no Brasil?. Revista Brasileira de Economia, v. 67, n. 1, p. 121-145, 2013.

RESENDE, G. M.; DE FIGUEIREDO, L. Testes de robustez: Uma aplicação para os determinantes do crescimento econômico estadual brasileiro entre 1960 e 2000. Revista Econômica do Nordeste, Fortaleza, v. 41, n. 1, 2010.

SALA-I-MARTIN, X. X. I just ran two million regressions. The American Economic Review, p. 178-183, 1997.

SOLOW, R. M. A contribution to the theory of economic growth. The Quarterly Journal of Economics, v. 70, n. 1, p. 65-94, 1956.

TUKEY, J. W. Kinds of Bootstraps and Kinds of Jackknives, Discussed in Terms of a Year of Weather--Related Data. PRINCETON UNIV NJ DEPT OF STATISTICS, 1987.

TURKHEIMER, F. E.; HINZ, R.; CUNNINGHAM, V. J. On the Undecidability Among Kinetic Models: From Model Selection to Model Averaging. Journal of Cerebral Blood Flow & Metabolism, v. 23, n. 4, p. 490-498, 2003.

WAGENMAKERS, Eric-Jan; FARRELL, S. AIC model selection using Akaike weights. Psychonomic Bulletin & Review, v. 11, n. 1, p. 192-196, 2004.

WANG, H.; ZHANG, X.; ZOU, G. Frequentist model averaging estimation: A review. Journal of Systems Science and Complexity, v. 22, n. 4, p. 732-748, 2009.

ZHANG, X.; WAN, A. TK; ZOU, G. Model averaging by jackknife criterion in models with dependent data. Journal of Econometrics, v. 174, n. 2, p. 82-94, 2013.

ZINI Jr., A. A. Regional income convergence in Brazil and its socio-economic determinants. Economia Aplicada, v. 2, n. 2, p. 383-411, abr./jun. 1998.

Apêndice – Estatísticas descritivas

	Var_dependente	*X4*	*X5*	*X14*	*X1*	*X2*	*X6*	*X7*	*X8*	*X9*	*X10*	*X11*
Média	3.7340	0.9724	1.9378	3.0138	0.3333	0.3333	0.2827	0.1768	0.1347	0.5284	48.5607	0.5897
Erro padrão	0.4868	0.0996	0.0965	0.1878	0.0648	0.0648	0.0153	0.0129	0.0059	0.0110	7.6398	0.0228
Mediana	2.2948	0.9183	1.8990	2.9319	0.0000	0.0000	0.2730	0.1687	0.1195	0.5404	35.8784	0.5884
Modo	#N/D	#N/D	#N/D	1.3000	0.0000	0.0000	#N/D	#N/D	#N/D	#N/D	#N/D	#N/D
Desvio padrão	3.5772	0.7320	0.7091	1.3799	0.4758	0.4758	0.1127	0.0949	0.0431	0.0812	56.1407	0.1672
Variância da amostra	12.7961	0.5358	0.5028	1.9042	0.2264	0.2264	0.0127	0.0090	0.0019	0.0066	3151.7780	0.0280
Curtose	-1.0618	-0.7509	3.4299	-0.5328	-1.5288	-1.5288	-0.8197	0.0754	-0.0895	-0.4350	9.3369	-0.4675
Assimetria	0.6849	-0.0894	1.4102	0.4487	0.7275	0.7275	0.0545	0.4820	0.7994	-0.0531	2.9096	0.2770
Intervalo	11.2178	2.9258	3.7539	5.5000	1.0000	1.0000	0.4452	0.4210	0.1840	0.3671	287.0987	0.7008
Mínimo	-1.0241	-0.6084	0.8660	1.0000	0.0000	0.0000	0.0694	0.0110	0.0734	0.3342	1.2625	0.2518
Máximo	10.1937	2.3174	4.6198	6.5000	1.0000	1.0000	0.5145	0.4320	0.2574	0.7013	288.3612	0.9525
Soma	201.6353	52.5079	104.6391	162.7465	18.0000	18.0000	15.2632	9.5484	7.2718	28.5340	2622.2764	31.8455
Contagem	54.0000	54.0000	54.0000	54.0000	54.0000	54.0000	54.0000	54.0000	54.0000	54.0000	54.0000	54.0000

	X17	*X19*	*X20*	*X22*	*X23*	*X24*	*X25*	*X26*	*X27*	*X28*	*X29*
Média	97.9138	56.1119	23.8727	1662.2022	6481.1852	13.5715	37.1239	57.1751	0.5971	10.9204	140.9081
Erro padrão	7.3162	0.7722	0.3858	51.5244	1678.8627	2.2493	2.8786	3.5086	0.0144	0.6392	19.1028
Mediana	89.2950	56.3225	25.0889	1560.8931	1601.5000	6.8549	33.5405	56.0443	0.6000	9.7000	94.1300
Modo	#N/D	48.5600	25.6875	#N/D	#N/D	#N/D	#N/D	#N/D	0.5800	7.4000	54.7600
Desvio padrão	53.7628	5.6741	2.8353	378.6252	12337.0708	16.5291	21.1531	25.7827	0.1061	4.6970	140.3764
Variância da amostra	2890.4379	32.1957	8.0387	143357.0323	152203315.0217	273.2123	447.4546	664.7473	0.0113	22.0621	19705.5403
Curtose	-0.2837	-0.9516	-0.2209	-0.4391	15.0985	3.2534	-0.7767	-1.1678	0.1609	2.9374	8.2452
Assimetria	0.7255	-0.0659	-0.9670	0.7651	3.6139	1.9128	0.4453	-0.1406	-0.2721	1.6063	2.6808
Intervalo	213.3100	22.1000	10.6750	1532.5643	70511.0000	73.6282	80.9973	90.3653	0.4800	22.6000	705.1200
Mínimo	22.3200	44.3600	16.7000	1015.3500	42.0000	0.2171	5.7197	6.2329	0.3300	4.3000	18.4900
Máximo	235.6300	66.4600	27.3750	2547.9143	70553.0000	73.8454	86.7170	96.5982	0.8100	26.9000	723.6100
Soma	5287.3450	3030.0450	1289.1245	89758.9183	349984.0000	732.8636	2004.6931	3087.4571	32.2450	589.7000	7609.0350
Contagem	54.0000	54.0000	54.0000	54.0000	54.0000	54.0000	54.0000	54.0000	54.0000	54.0000	54.0000