



UNIVERSIDADE FEDERAL DO CEARÁ
FACULDADE DE ECONOMIA, ADMINISTRAÇÃO, ATUÁRIA
E CONTABILIDADE - FEAAC
CENTRO DE PÓS-GRADUAÇÃO EM ECONOMIA - CAEN

SAMUEL SAYMON DE MORAIS MATOS

UMA APLICAÇÃO DE PAINEL DINÂMICO COM VARIÁVEL
THRESHOLD PARA A PROPORÇÃO DE POBRES DOS ESTADOS
BRASILEIROS

FORTALEZA
2011

SAMUEL SAYMON DE MORAIS MATOS

UMA APLICAÇÃO DE PAINEL DINÂMICO COM VARIÁVEL
THRESHOLD PARA A PROPORÇÃO DE POBRES DOS ESTADOS
BRASILEIROS

Dissertação submetida ao Curso de Pós-Graduação em
Economia, da Universidade Federal do Ceará, como requisito parcial
para a obtenção do grau de Mestre em Economia.

Orientador: Prof. Dr. Fabrício Carneiro Linhares

SAMUEL SAYMON DE MORAIS MATOS**UMA APLICAÇÃO DE PAINEL DINÂMICO COM VARIÁVEL
THRESHOLD PARA A PROPORÇÃO DE POBRES DOS ESTADOS
BRASILEIROS**

Dissertação submetida à Coordenação do Curso de Pós-Graduação em Economia da Universidade Federal do Ceará, como requisito parcial para a obtenção do grau de Mestre em Economia

Aprovada em: _____

BANCA EXAMINADORA

Prof. Dr. Fabrício Carneiro Linhares
CAEN/UFC

Prof. Dr. João Mário Santos de França
CAEN/UFC

Dr. Carlos Alberto Manso
Membro Externo

Aos meus pais, Vicente e Selma.

Resumo

A finalidade deste trabalho é avaliar convergência da proporção de pobres (P_0) em dezenove estados brasileiros mais o Distrito Federal. Para tanto, são feitas adaptações de dois modelos de renda *per capita* em painel dinâmico que realizam testes de convergência. O primeiro é um modelo linear desenvolvido por Evans e Karras (1996) e o segundo é um modelo não-linear com variável limiar (*threshold*) de Beyaert e Camacho (2008). Os estados selecionados foram Piauí, Maranhão, Ceará, Rio Grande do Norte, Paraíba, Pernambuco, Alagoas, Sergipe, Bahia, Minas Gerais, Espírito Santo, Rio de Janeiro, São Paulo, Paraná, Santa Catarina, Rio Grande do Sul, Goiás, Mato Grosso, Mato Grosso do Sul e mais o Distrito Federal. Para aumentar a eficiência dos testes e com a finalidade encontrar possíveis clubes de convergência, os estados foram divididos em dois grupos: os nordestinos e os não-nordestinos. De acordo com os testes, nem os estados nordestinos convergem e nem o grupo dos outros estados convergem. Nos dois casos o modelo linear é preferido ao não linear. Já para o grupo com todos os estados juntos, o modelo não-linear é o escolhido como mais adequado. Os resultados empíricos encontrados para este grupo concluem em favor de convergência absoluta entre os estados selecionados.

Palavras-Chave: Pobreza, Painel Dinâmico Não-linear, Convergência, Variável Limiar.

Abstract

The aim of this study is to investigate the convergence of poverty headcount poverty (P_0) in nineteen Brazilian states plus the Federal District. To this end, adjustments have been made from two different models of per capita income in a dynamic panel. The first is a linear model developed by Evans and Karras (1996) and the second is a nonlinear model with the threshold variable of Beyaert and Camacho (2008). The selected states were Piauí, Maranhão, Ceara, Rio Grande do Norte, Paraíba, Pernambuco, Alagoas, Sergipe, Bahia, Minas Gerais, Espirito Santo, Rio de Janeiro, São Paulo, Paraná, Santa Catarina, Rio Grande do Sul, Goiás, Mato Grosso, Mato Grosso do Sul and the Federal District. To increase the efficiency of the tests and in order to find possible convergence clubs, the states have been divided in two groups: the non-Northeast and Northeast. According to the tests, neither the northeastern states converge nor does the group of other states converge. In both cases the linear model is preferred to non-linear. For the group with all the states, the non-linear model is the most suitable. The empirical results for this group concluded in favor of absolute convergence among selected states.

Keywords: Poverty, Dynamic Nonlinear Panel, Convergence, Threshold Variable

Lista de Tabelas

TABELA 1 – Resultados dos testes para os estados nordestinos;

TABELA 2 – Resultados dos testes para os estados não- nordestinos;

TABELA 3 – Resultados dos testes para todos os Estados.

Lista de Figuras

FIGURA 1 – Análise gráfica para os estados nordestinos;

FIGURA 2 – Análise gráfica para os estados não-nordestinos;

FIGURA 3 – Análise gráfica para todos os estados.

Sumário

1. Introdução.....	10
2. Revisão de Literatura.....	13
2.1. Pobreza: Estudos no Brasil.....	13
2.2. Pobreza: Estudos Internacionais.....	15
2.3. Estudos Análogos: Metodologia Econométrica.....	18
3. Metodologia.....	19
3.1. Modelo de Evans-Karras.....	19
3.2. Modelo de Beyart-Camacho.....	25
3.3. Linear versus Modelo não-linear com variável Threshold.....	29
3.4. Testes de Convergência para o modelo Beyart-Camacho.....	31
3.5. Adaptações dos Modelos.....	35
4. Descrição dos dados e Índices de Pobreza.....	36
4.1. Base de dados.....	37
4.2. Medidas de Pobreza.....	38
4.2.1. Linhas de Pobreza.....	38
5. Resultados.....	43
5.1 Estados Nordesteiros.....	44
5.2. Estados Não-Nordestinos.....	46
5.3. Todos os Estados.....	48
6. Conclusões	51
7. Notas.....	54
8. Referências Bibliográficas.....	55

1. Introdução

As recentes políticas sociais suscitaram a curiosidade de muitos pesquisadores com relação à dinâmica dos indicadores de pobreza e desigualdade no Brasil. Com isso, surgiram estudos relevantes que promovem elucidações importantes sobre a pobreza neste país.

Silveira Neto (2005) mostra que o crescimento pró-pobre na região Nordeste na década de 1990 foi menor do que as outras regiões do país. Manso et al. (2006) evidenciam que os componentes de crescimento da renda média e de sua distribuição são suficientes para esclarecer grande parte das oscilações das taxas de pobreza entre os estados brasileiros no período de 1995 a 2004.

Neri (2008) aponta que desde 2001 o ritmo de diminuição na desigualdade de renda brasileira é similar ao ritmo de concentração de renda vivido pelo Brasil na época do Milagre Econômico. Segundo este autor, o aumento da nova classe média é sustentável para os próximos anos.

O presente trabalho está inserido na agenda de pesquisa dos trabalhos anteriormente citados, uma vez que este averigua a evolução temporal da pobreza entre os estados brasileiros. O objetivo, portanto, é verificar se existe convergência de pobreza entre os estados brasileiros, classificando-a, caso exista, em absoluta ou condicional.

Existem outros inúmeros artigos que buscam encontrar as causas da pobreza no Brasil. Ramos (2007) aponta que a desigualdade de renda se reduziu bastante no Brasil no período pós-real. Ainda assim, segundo ele, há uma disparidade imensa nos rendimentos do trabalho, seja este individual ou familiar. Conforme Ramos (2007) a principal causa dessa heterogeneidade pode ser atribuída à educação. Na mesma linha de pesquisa, Sachsida *et al.* (2004) mostram que as diferenças salariais dos brasileiros variam de acordo com o nível educacional.

Vinculando pobreza a crescimento econômico, Hoffman (2005) pesquisa a elasticidade da pobreza em relação à renda média e a desigualdade de renda brasileira. Ele conclui que, existindo crescimento econômico, quanto mais desigual for a região menor será o seu crescimento pró-pobre.

O intuito de compreender essa relação entre crescimento econômico, desigualdade de renda e pobreza existe desde Kuznets (1955), com a famosa curva U invertido, na qual diz que a desigualdade piora nos estágios iniciais de desenvolvimento e vai se reduzindo no decorrer do tempo.

Desde este seminal trabalho, vários estudos procuraram verificar empiricamente esta relação. Dentre os mais recentes, podemos citar: Ravallion (1997), White e Anderson (2000) e Banerjee e Duflo (2003). Dentro desse grupo de artigos, podemos destacar, ainda, Fields (2001), onde é demonstrado que crescimento econômico gera aumento na renda e, conseqüentemente, oscilações na taxa de pobreza.

De forma geral, o que estes artigos mostram é que um aumento crescente na renda média gera um transbordamento de renda para as classes mais baixas, diminuindo assim as taxas de pobreza e os índices de desigualdade existentes. Esta relação existente entre

aumento de renda e diminuição da pobreza é que permite sugerir que no período em que os trabalhos empíricos localizaram a formação de clubes de convergência de renda, existiu, paralelamente, formação de clubes de convergência de pobreza.

Em outros países, muitos estudos já foram feitos com o objetivo de pesquisar as suas respectivas taxas de pobreza no decorrer do tempo. Pode-se destacar Wang e Dayanandan (2006) que aplicaram testes de raiz unitária para dados em painel para o Canadá e suas províncias. E, Raj e Slottje (1997) que aplicaram testes de raiz unitária para os estados norte-americanos.

Dessa forma, o objetivo deste trabalho consiste em verificar se existe um processo de convergência da proporção de pobres entre os estados brasileiros. Dois aspectos devem ser ressaltados. Primeiro, seguindo Dayanandan (2006) e Raj e Slottje (1997) entender a dinâmica temporal da pobreza pode indicar a forma como este índice reage a certos tipos de choques (com maior ou menor persistência) e permite a utilização das séries de pobreza em modelos de regressão que não gerem regressões espúrias.

O segundo aspecto decorre da hipótese de que numa economia fechada, espera-se que a reação do índice de pobreza devido a certos tipos de políticas seja relacionado a estrutura socioeconômica do estado. Desse modo, estados econômico e socialmente semelhantes (como os do Nordeste, por exemplo), espera-se que converjam ou não de forma análoga. Essa hipótese possibilita a existência de clubes de convergência da pobreza no Brasil.

Para realizar a presente pesquisa, foi utilizado dois modelos de painel dinâmico desenvolvidos para estudar a convergência da renda *per capita* entre países. O primeiro é um modelo auto-regressivo linear desenvolvido por Evans e Karras (1996), o segundo é uma evolução do primeiro, um modelo auto-regressivo não-linear com variável limiar (*threshold*, TAR), desenvolvido por Beyaert e Camacho (2008).

A adaptação a estes modelos se deu com a substituição do índice de renda utilizado no modelo de Evans-Karras e Beyaert-Camacho pelo o índice de pobreza que mensura a proporção de pobres, P_0 . Os resultados foram obtidos para a amostra completa, contendo 19 estados brasileiros, e para dois grupos de estados, os estados nordestinos e os não-nordestinos.

A principal contribuição dessa dissertação para a literatura sobre pobreza está relacionada com a metodologia imposta. Além disso, deve ser observado o período da análise, 1977-2009. Por conta da indisponibilidade de dados e os altos momentos inflacionários vividos na década de 1980 e início da década de 1990, vários estudos sobre pobreza e renda restringem suas análises a períodos pós-1994.

Esta dissertação está dividida da seguinte forma. A seção 2 faz uma revisão de literatura dos estudos que avaliam a evolução temporal da pobreza, bem como faz referência aos trabalhos que já utilizaram o arcabouço metodológico usados nesta dissertação. A seção 3 explica a metodologia usada neste trabalho. A seção 4 descreve a base de dados empregada e faz uma revisão geral dos principais índices de pobreza existentes. A seção 5 apresenta os resultados alcançados e seus significados, enquanto que a última seção exhibe as conclusões do trabalho.

2. Revisão de Literatura

2.1 Pobreza: Estudos no Brasil

A relevância em se estudar convergência de pobreza entre os estados brasileiros relaciona-se com o fato de que se pode vislumbrar como será a distribuição da pobreza brasileira nos próximos anos.

Um quadro que evidencia redução da miséria juntamente com convergência de pobreza entre os estados brasileiros, significaria que pode-se esperar um futuro com menos desigualdade entre as regiões brasileiras. Por sua vez, uma constatação de que não há convergência, ou que a mesma só existe se condicionada a algum fator, nos permite censurar as políticas de combate à pobreza vigentes.

Somado a motivação de traçar o futuro com base em evidências empíricas do passado e do presente, o interesse em estudar a dinâmica temporal da pobreza brasileira tem se acentuado recentemente pelo fato do Brasil ter apresentado nos últimos anos um aumento na média da sua taxa de crescimento econômico seguido de consideráveis reduções em índices de desigualdade (BARROS et al. 2010).

Quando a economia de um país passa por um processo de crescimento, a distribuição de renda entre suas classes sociais pode sofrer modificações, gerando assim, oscilações nas taxas de pobreza (FIELDS, 2001). Dado as últimas variações na taxa de crescimento econômico do Brasil, surgiu o interesse de vários pesquisadores sobre a dinâmica da pobreza brasileira.

Barros *et al.* (2001) aponta que a causa dos elevados índices de pobreza no Brasil está relacionada com o elevado grau de desigualdade na distribuição de renda nas últimas décadas. Eles também concluem que o Brasil do final do século passado não é um país pobre, mas sim um país extremamente injusto e desigual, com muitos pobres.

Hoffman (2006) mostra que na última década a pobreza se reduziu bastante no Brasil. Concomitante a isto, a desigualdade de renda diminuiu. Segundo ele, a causa da redução da pobreza no Brasil está atrelada aos programas de transferências de renda do Governo Federal, tais como o Bolsa-Família, e os juros e dividendos da dívida brasileira. Além disso, ele constata que a região mais sensível aos programas de assistência social é a nordestina.

Silveira et al. (2007) usando dados da Pesquisa de Orçamento Familiar (POF) do IBGE, faz um arcabouço geral das linhas de pobreza com o objetivo de localizar quais as regiões brasileiras que apresentam maiores índices de pobreza. Eles concluem que a região Nordeste, Norte e o norte de Minas Gerais são as áreas brasileiras que apresentam maior proporção de pobres, enquanto que a região Sul juntamente com o estado de São Paulo são as áreas que apresentam menor pobreza.

Barros et al. (2007) mostra que menos de um quarto dos 74 países que possuem dados temporais de desigualdade de renda conseguiram diminuir a pobreza como o Brasil no período 2001-2005. Além disso, eles mostram que a diminuição de pobres no Brasil independe da medida de desigualdade, da existência de economias de escala ou de necessidades diferenciadas de crianças, de adultos e de idosos.

Com o grande número de artigos publicados que estuda a redução acentuada da pobreza no Brasil nos últimos anos, Soares (2009), através do coeficiente de Gini, compara a diminuição da pobreza no Brasil com os países pertencentes à Organização para a Cooperação e Desenvolvimento Econômico (OCDE). O resultado é que o Brasil, juntamente com a Espanha, é o país que mais reduz a desigualdade de renda.

Com o objetivo de verificar se as variações na taxa de crescimento econômico provocaram distribuição de renda e convergência entre os estados e municípios brasileiros, ou se estas oscilações no crescimento ficaram concentradas em algumas regiões, vários estudos avaliam se existiu ou não uma convergência de renda entre os estados e os municípios brasileiros (TROMPIERE, CASTELAR e LINHARES, 2008) e (COELHO e FIGUEREIREDO, 2007).

O estudo temporal da pobreza não se limita apenas ao Brasil, diversos estudos, com o objetivo de traçar diretrizes mundiais sobre o combate à pobreza, avaliam as variações dos índices de pobreza entre países no decorrer do tempo. O próximo tópico traz uma revisão de alguns desses artigos internacionais. Além disso, analisa artigos no Canadá e Estados Unidos que avaliaram temporalmente suas respectivas taxas de pobreza.

2.2. Pobreza: Estudos Internacionais.

Há vários estudos internacionais que avaliam o desempenho de taxas de pobreza no decorrer do tempo. Carter e Barrett (2006), com base em dados em painel sugerem algumas estratégias viáveis para estimar empiricamente a armadilha da pobreza e a persistência da pobreza, bem como desenvolvem extensões da classe de *FGT* (α), Foster, Greer e Thorbecke (1984) de índices de pobreza.

Bourguignon (2003) analisa a tríade pobreza, desigualdade de renda e crescimento econômico numa série temporal para vários países. De forma geral, ele aponta que crescimento econômico só afetará a vida dos mais pobres se existir redução na desigualdade de renda. Além disso, ele conclui que as diferenças entre os países investigados influenciaram nos resultados obtidos para a elasticidade pobreza-crescimento e pobreza-desigualdade.

Dollar e Kraay (2002) avaliam a pobreza para 92 países nas últimas quatro décadas. Eles mostram que a renda média da quinta parte da população mais pobre dos países em ascensão aumenta, em média, proporcionalmente a renda da média de sua população. Dessa forma, políticas que promovem crescimento econômico promovem aumento na renda média dos mais pobres. Nesse artigo, também é encontrado evidências que a estabilização da inflação, disciplina fiscal por parte do governo e abertura do comércio internacional diminui o número de pobres dos países analisados.

Além desses artigos de ordem mundial, existem trabalhos que estudam a taxa de pobreza interna de determinados países e sua distribuição entre seus estados. O objetivo desses estudos, porém, é definir qual a ordem de integração desses índices de pobreza através de testes de raiz unitária e, dessa forma, poder afirmar se eles são estacionários ou não estacionários. Há alguns trabalhos que não chegam a resultados conclusivos. Isto porque os testes de raiz unitária aplicados revelam ordens de integração diferentes.

Wang e Dayanandan (2006) aplicaram para o Canadá e suas dez províncias, alguns testes de raiz unitária para um índice relativo. A medida escolhida foi a LICO, *low income cut-off*, pois, segundo os autores, era o índice de pobreza canadense que apresentava uma série histórica mais longa.

Para calcular a LICO é feito um levantamento do padrão de consumo das famílias canadenses nos últimos quatro anos com uma cesta de bens composta por alimentação, moradia e roupas. Feito isto, calcula-se o percentual médio da renda que as famílias canadenses gastam com essa cesta. As famílias sob a LICO são aquelas que gastam 20% a mais desse percentual médio canadense. Dessa forma, vemos que a LICO não é um índice de pobreza, mas sim uma medida relativa de desigualdade.

Os testes ADF, indicado Dickey e Fuller (1979), PP, esboçado por Philips e Perron (1988), e o DF-GLS, mostrado por Elliot, Rothenberg e Stock (1996) foram bastante consistentes em apontar que a medida de desigualdade do Canadá, como um todo, é uma série não estacionária.

Os testes de raiz unitária para dados em painel aplicados por Wang e Dayanandan (2006), foram o IPS, (IM, PESARAM e SHIN, 1997) e o LL (LEVIN, LIN, CHU, 1993). Os resultados apontaram, novamente, não-estacionariedade na série.

Nos Estados Unidos, Raj e Slottje (1997) são os pioneiros a testar a estacionariedade da taxa de pobreza norte-americana. Os resultados não conseguem definir qual a ordem de integração da taxa de pobreza.

Para seu estudo, Raj e Slottje (1997) utilizaram como índice de pobreza o número de pessoas que vivem abaixo da linha de pobreza definida pelo governo norte-americano, a proporção de pobres do P_0 . Os primeiros testes aplicados foram o ADF e o KPSS, sugerido por Kwiatkowski et al. (1992), os testes indicaram que a série é não-estacionária.

A fim de descobrir se a série era integrada de ordem 1, $I(1)$, Raj e Slottje (1997), defasaram a série e reaplicaram os testes. Desta vez os testes não convergiram, o teste KPSS aceitou a hipótese nula de estacionariedade para a série defasada, enquanto que o teste ADF não rejeitou a hipótese nula de raiz unitária.

Outro teste aplicado à série foi o de Zivot-Andrews, recomendado por Zivot e Andrews (1992), desta vez a hipótese de raiz unitária foi rejeitada. O teste de Zivot-Andrews sugeriu que a série é estacionária, mas com uma quebra estrutural, o que contraria os primeiros testes. Desta forma, os autores afirmam que é duvidoso concluir a qual ordem de integração a taxa de pobreza norte-americana pertence.

2.3. Estudos Análogos: Metodologia Econométrica

Há dois trabalhos que usam a mesma metodologia utilizada no presente estudo. O primeiro é o próprio Beyaert e Camacho (2008), e o segundo é o Ferreira e Vieira (2009). Os dois estudos analisam a convergência de renda entre países.

Beyaert e Camacho (2008) usam como base de dados a renda *per capita* de países da Europa no período de 1950 a 2004. Primeiramente são selecionados os países mais

ricos da Europa e aplicado um conjunto de testes. Logo após adiciona-se outros países da Europa menos desenvolvidos e aplica-se o mesmo conjunto de testes.

Ferreira e Vieira (2009) fazem o mesmo procedimento de Beyaert e Camacho (2008). Só que dessa vez, os países selecionados são os da América, juntos e divididos em seus respectivos grupos econômicos. Os testes são aplicados duas vezes para cada grupo de países. Ou seja, testes pré-MERCOSUL e pós-MERCOSUL para os países partícipes do acordo e assim por diante para o grupo de países do CAN e do Nafta.

Os resultados nestes dois artigos implicam que o modelo linear é indicado para alguns grupos, enquanto que em outros o modelo não-linear é o que melhor define o processo temporal.

3. Metodologia

Neste tópico será apresentado o modelo auto-regressivo linear proposto por Evans e Karras (1996), suas limitações e seus testes de convergência. Além disso, se explicará o modelo auto-regressivo não-linear de Beyaert e Camacho (2008) e os testes de convergências proposto por este modelo. Por fim, será demonstrado as adaptações necessárias nesses modelos para a aplicação neste trabalho.

3.1. Modelo de Evans-Karras

O modelo linear auto-regressivo proposto por Evans e Karras (1996) possui o seguinte formato:

$$\Delta g_{n,t} = \delta_n + \rho_n g_{n,t-1} + \sum_{i=1}^p \varphi_{n,i} \Delta g_{n,t-i} + \varepsilon_{n,t} \quad (1)$$

Onde ρ_n representa uma combinação de parâmetros auto-regressivos, $n = 1, \dots, N$, e $t = 1, \dots, T$, sendo n os N países selecionados e t o período de tempo.

Como dito, Evans e Karras (1996) analisa convergência de renda entre n economias. Assim, $\Delta g_{n,t}$ corresponde à primeira diferença da variável $g_{n,t}$, que é definida como $\Delta g_{n,t} = y_{n,t} - \bar{y}_t$. Onde, $y_{n,t} = \log(Y_{n,t})$, $Y_{n,t}$ é a renda *per capita* do país n e $\bar{y}_t = \frac{1}{N} \sum_{n=1}^N y_{n,t}$, o que seria uma média do log da renda *per capita* dos países selecionados.

Evans e Karras (1996) mostram que se $\rho_n = 0$, os N países divergem. Já, se $0 < -\rho_n < 1$, há convergência, sendo absoluta quando $\delta_n = 0$ e condicional caso contrário.

Para os testes em (1), Evans e Karras (1996), propõem o seguinte procedimento: primeiro aplica-se Mínimos Quadrados Ordinários (MQO) em (1) para obter estimativas

de ε_n, s_n . Com a estimativa de ε_n , transforma-se $w_{n,t} = g_{n,t}/s_{n,t}$. Depois, obtém-se a estimativa de ρ por MQO e sua estatística t através de

$$\Delta w_{n,t} = \delta_n + \rho_n w_{n,t-1} + \sum_{i=1}^p \varphi_{n,i} \Delta w_{n,t-i} + \varepsilon_{n,t}. \quad (2)$$

Dependendo do valor do teste t , rejeita-se a hipótese nula abaixo, das hipóteses de teste abaixo:

$$H_0: \rho_n = 0 \forall n, \quad H_A: \rho_n \neq 0 \forall n \quad (3)$$

A hipótese nula significa que não existe convergência, isto é, a série possui raiz unitária. Se a hipótese nula não for aceita, testamos se a convergência é absoluta ou condicional. A estatística usada para testar a convergência absoluta *versus* condicional é

$$\Phi_n = \frac{1}{N-1} \sum_{n=1}^N (t_{\delta_n^*}^2) \quad (4)$$

Onde é $t_{\delta_n^*}$ é a estatística t da estimativa de δ_n em (1).

Se Φ_n for muito pequeno, aceitamos a hipótese nula de convergência absoluta, caso contrário, a convergência é condicional.

No modelo de Evans e Karras (1996) há a suposição de que os erros em (1) são contemporaneamente não correlacionados, desta forma os testes de convergência absoluta e condicional tomam distribuições assintóticas padrão, quando $N \rightarrow \infty$ e $T \rightarrow \infty$.

Conforme Beyaert e Camacho (2008), essas hipóteses são muito fortes. Elas significam que os choques são não correlacionados no decorrer do tempo e, mais ainda, que eles são não correlacionados entre as observações, no caso do estudo deles países, no nosso caso, os estados brasileiros. Em outras palavras, é um tanto ilusório acreditar que uma política do Governo Federal de combate a pobreza no estado de São Paulo não deva afetar outros estados. Além disso, como estamos trabalhando com alguns estados do Brasil, N é pequeno.

A hipótese sobre os erros serem não correlacionados entre as observações é relaxada com o uso de simulações de *bootstrap*. A saber:

Definamos $\varepsilon_n = [\varepsilon_{n,1}, \dots, \varepsilon_{n,T}]'$ e $\varepsilon = [\varepsilon_1', \varepsilon_2', \dots, \varepsilon_N']'$. A matriz de variância-covariância dos erros será uma matriz não diagonal dada por:

$$V = \Omega \otimes I_T \quad (5)$$

Sendo

$$\Omega = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1N} \\ \sigma_{12} & \sigma_{22} & \cdots & \sigma_{2N} \\ \cdots & \cdots & \cdots & \cdots \\ \sigma_{1N} & \sigma_{2N} & \cdots & \sigma_{NN} \end{bmatrix} \quad (6)$$

Onde $\sigma_{nm} = cov(\varepsilon_{n,t}, \varepsilon_{m,t})$, para todo m, n . Desta forma, como a matriz V é não-diagonal devemos utilizar o método de estimação FGLS¹ (Mínimos Quadrados Generalizados Viáveis). Para tanto, tomemos:

$$G_n = [g_{n,1}, \dots, g_{n,T}]' \text{ para } n=1, \dots, N \quad (7)$$

$$G = [G_1', \dots, G_N']'; \quad (8)$$

$$\Delta G = [\Delta G_1', \dots, \Delta G_N']' \quad (9)$$

Onde ΔG é a primeira diferença de G_n .

Definamos também a coluna de vetor β de forma que os parâmetros de cada observação estejam juntos, da seguinte forma:

$$\beta = (\delta_1, \dots, \delta_N; \rho_1, \dots, \rho_N; \varphi_{1,1}, \dots, \varphi_{N,1}; \dots; \varphi_{1,p}, \dots, \varphi_{N,p})' \quad (10)$$

Em forma de SUR², podemos expressar o modelo da seguinte forma:

$$\Delta G = X\beta + \varepsilon \quad (11)$$

Onde

$$X = (\check{\imath}, \check{G}_{-1}, \Delta \check{G}_{-1}, \dots, \Delta \check{G}_{-p}) \quad (12)$$

$$\check{\imath} = \begin{bmatrix} \bar{1}_T & & 0 \\ & \ddots & \\ 0 & & \bar{1}_T \end{bmatrix} \quad (13)$$

Sendo $\check{\imath}$ um vetor coluna de T elementos 1.

$$\check{G}_{-1} = \begin{bmatrix} G_{1,-1} & & 0 \\ & \ddots & \\ 0 & & G_{N,-1} \end{bmatrix} \quad (14)$$

Sendo $G_{N,-1}$ a defasagem de um período de G_N . Dessa forma:

$$\Delta\check{G}_{-i} = \begin{bmatrix} \Delta G_{1,-i} & & 0 \\ & \ddots & \\ 0 & & \Delta G_{N,-i} \end{bmatrix} \quad (15)$$

De forma análoga, $G_{n,-i}$ é a defasagem de i períodos de G_N .

Para estimar o modelo por FGLS, deve-se saber quem é (6). A fim de encontrar Ω , estimamos (11) por OLS e encontra-se $\hat{\Omega}$, como estimativa de Ω . A estimativa das variâncias e covariâncias dessa matriz será $S_{nm} = \frac{1}{T} \sum_{t=1}^T e_{nt}e_{mt}$ para $n, m = 1, \dots, N$. Onde os resíduos e são os correspondentes de cada observação no período t .

A estimativa de β por FGLS terá o seguinte formato:

$$\hat{\beta}_{FGLS} = [X' \hat{V}^{-1} X]^{-1} X' \hat{V}^{-1} \Delta G \quad (15)$$

Onde $\hat{V} = \hat{\Omega} \otimes I_T$.

Para testar se há divergência ou convergência, deve-se estimar (11) com a restrição $\rho_n = \rho$ para todo n e verificar a estatística t dessa estimação com restrição. Não temos os valores críticos tabelados para essas estatísticas. Para contornar este problema, usemos simulações de *bootstrap*.

A simulação de *bootstrap* segue da seguinte forma: encontra-se (1) por MQO com a restrição que $\rho_n = 0$. Rearranja-se os resíduos dessa restrição da seguinte forma:

$$E^o = \begin{bmatrix} e_{1,1}^o & e_{2,1}^o & \cdots & e_{N,1}^o \\ e_{1,2}^o & e_{2,2}^o & \cdots & e_{N,2}^o \\ \vdots & \vdots & \cdots & \vdots \\ e_{1,T}^o & e_{2,T}^o & \cdots & e_{N,T}^o \end{bmatrix} \quad (17)$$

Onde $n = 1, \dots, N$ e $t = 1, \dots, T$. As linhas de (17) são mescladas, a fim de que se encontre uma nova série de tempo $\{e_{n,t}^{o*}, t = 1, \dots, T\}$ dos resíduos que preserve a correlação contemporânea inicial de cada observação. Beyaert e Camaho (2008) recomendam Maddala e Wu (2004) para maiores esclarecimentos. Com as estimativas encontradas por FGLS e usando esses resíduos embaralhados, encontramos novas estimativas para (1) com a restrição que $\rho_n = 0$.

Este processo é repetido 1000 vezes e em cada vez é calculado o valor da estatística t . O valor crítico de *bootstrap* é o percentual de vezes que as estatísticas geradas por *bootstrap* fiquem do lado esquerdo da estatística t encontrada para os dados observados.

A simulação de *bootstrap* para testar a convergência absoluta *versus* condicional é realizada da mesma maneira. O modelo (1) é estimado por SUR sem a imposição de restrições e a estatística é calculada.

$$\Phi = \frac{1}{N-1} \left\{ \sum_{n=1}^N [t(\hat{\delta}_{FGLS,n})]^2 \right\} \quad (18)$$

Onde $\hat{\delta}_{FGLS,n}$ é a estimativa FGLS de δ . Depois, (11) é estimada com a restrição $\delta_n = 0$ para todo n . O mesmo procedimento com os resíduos é realizado (coloca-se numa matriz e misturam-se as linhas). Com esses resíduos permutados, com as estimativas encontradas por FGLS, e com a restrição $\delta_n = 0$ para todo n , encontra-se valores para a variável dependente. Calculamos e ordenamos as estatísticas de testes. O p-valor *bootstrap* é o percentual de vezes que as estatísticas de testes ordenadas anteriormente se encontram a direita da estatística que encontramos para os dados observados.

Outra limitação do modelo de Evans-Karras é a linearidade. Em termos econômicos, linearidade significa que a dinâmica de convergência entre as observações é a mesma durante o período da análise. Esta suposição é flexibilizada no modelo proposto por Beyaert e Camacho (2008). Neste modelo, a dinâmica de convergência não possui mais só o formato uniforme, mas depende das características econômicas e sociais das unidades observadas. O modelo de Beyaert e Camacho será explicado a seguir.

3.2. Modelo de Beyart-Camacho

Beyart e Camacho (2008) propõem a aplicação de um modelo auto-regressivo não linear com variável *threshold* (TAR) com o seguinte formato:

$$\Delta g_{n,t} = [\delta_n^I + \rho_n^I g_{n,t-1} + \sum_{i=1}^p \varphi_{n,i}^I \Delta g_{n,t-i}] I_{\{z_{t-1} < \lambda\}} + [\delta_n^{II} + \rho_n^{II} g_{n,t-1} + \sum_{i=1}^p \varphi_{n,i}^{II} \Delta g_{n,t-i}] I_{\{z_{t-1} \geq \lambda\}} + \varepsilon_{n,t} \quad , \text{ sendo } n = 1, \dots, N \text{ e } t = 1, \dots, T \quad (19)$$

Vê-se que $I\{x\}$ é uma função indicadora que possui o valor 1 quando x é verdadeiro e zero, caso contrário. É fácil ver que quando $z_{t-1} < I$ o modelo passa a ser:

$$\Delta g_{n,t} = [\delta_n^I + \rho_n^I g_{n,t-1} + \sum_{i=1}^p \varphi_{n,i}^I \Delta g_{n,t-i}] I_{\{z_{t-1} < \lambda\}} + \varepsilon_n \quad (20)$$

E quando $z_{t-1} \geq I$, o modelo passa a ser:

$$\Delta g_{n,t} = [\delta_n^{II} + \rho_n^{II} g_{n,t-1} + \sum_{i=1}^p \varphi_{n,i}^{II} \Delta g_{n,t-i}] I_{\{z_{t-1} \geq \lambda\}} + \varepsilon_n \quad (21)$$

Beyaert e Camacho (2008) chamam de “regime I” o caso onde $z_{t-1} < I$ e regime II o caso onde $z_{t-1} \geq I$.

O parâmetro λ é o parâmetro *threshold* que indica o valor limiar entre os regimes I e II para a variável z_{t-1} . Note que, se $z_{t-1} < \lambda$ para qualquer t ou $z_{t-1} \geq \lambda$ para qualquer t , o modelo TAR torna-se igual ao modelo de Evans-Karras.

No modelo não-linear, o parâmetro *threshold* é desconhecido, Beyaert e Camacho (2008) colocam a restrição que $0 < \pi_1 \leq P[z_{t-1} < \lambda] \leq 1 - \pi_1$ na estimação. Ou seja, nenhum dos regimes pode ter fração da amostra menor que π_1 . O valor de π_1 fica em torno de 0,10 - 0,15.

Há duas possibilidades de escolher a variável de transição z_t . Uma é de forma exógena, quando ela difere da variável $g_{n,t}$ e a outra é de forma endógena. A forma endógena foi escolhida pelo trabalho de Beyaert e Camacho (2008) e, da mesma forma, deste trabalho. Para escolher z_t de forma endógena $z_t = g_{m,t} + g_{m,t-d}$ para algum m e $0 < d \leq p$, sendo que m e d não são fixados a priori, mas sim determinados endogenamente. Estatisticamente, isto significa que z_t deve ser estacionário, se as unidades observacionais convergem ($g_{n,t} \sim I(0)$, para todo n e todos os regimes) ou não ($g_{n,t} \sim I(1)$, para um ou ambos regimes).

O modelo (19) pode ser estimado por MQO. Entretanto, por não sabemos do valor da variável *threshold*, nem da variável de transição e por conta da dependência dos coeficientes, e da estrutura de (5) e (6), Beyaert e Camacho sugerem o uso de GLS³.

Suponhamos que λ , m e d sejam conhecidos e estejam no vetor $\theta_0 = (\lambda_0, m_0, d_0)$. Condicionado a θ_0 o modelo pode ser um painel com variáveis binárias conhecidas. Suponha que o número de observações disponíveis no tempo para cada observação é $(T + p + 1)$ de forma que existam $(p + 1)$ observações disponíveis antes do período $t = 1$.

O modelo pode ser escrito na forma de SUR:

$$\Delta G = [X \otimes \check{I}_{I,\theta_0} \ ; \ X \otimes \check{I}_{II,\theta_0} \] \begin{bmatrix} \beta_{I,\theta_0} \\ \cdots \\ \beta_{II,\theta_0} \end{bmatrix} + \varepsilon \quad (22)$$

Onde β_{I,θ_0} e β_{II,θ_0} são os β 's do modelo (19), dos regimes I e II, respectivamente, quando, $\lambda = \lambda_0$, $m = m_0$ e $d = d_0$. \check{I}_{I,θ_0} refere-se a um vetor $(NT \times 1)$ obtido do empilhamento N vezes do seguinte vetor de dimensão $(T \times 1)$ de variáveis binárias:

$$I_{I,\theta_0} = [I_{Z_0,p < \lambda_0}, I_{Z_0,p+1 < \lambda_0}, \cdots, I_{Z_0,T-1 < \lambda_0}]' \quad (23)$$

Onde $Z_{0,t} = g_{m_0,t} - g_{m_0,t-d_0}$, similarmente para o segundo regime:

$$I_{II,\theta_0} = [1 - I_{Z_0,p < \lambda_0}, 1 - I_{Z_0,p+1 < \lambda_0}, \cdots, 1 - I_{Z_0,T-1 < \lambda_0}]' \quad (24)$$

Resumidamente, pode-se escrever o modelo (22):

$$\Delta G = \check{X}_{\theta_0} \beta_{\theta_0} + \varepsilon \quad (25)$$

Estimando esse modelo por FGLS⁴

$$\hat{\beta}_{\theta_0, FGLS} = [\check{X}'_{\theta_0} \hat{V}_0^{-1} \check{X}_{\theta_0}]^{-1} \check{X}'_{\theta_0} \hat{V}_0^{-1} \Delta G \quad (26)$$

Onde $\hat{V}_0 = \hat{\Omega}_0 \otimes I_T$ e $\hat{\Omega}_0 = [s_{nm,0}]$ com $s_{nm,0} = \frac{1}{T} \sum_{t=1}^T e_{nt,0} e_{mt,0}$, para $n, m = 1, \dots, N$ e com $e_{lt,0}$ obtido do MQO (29) correspondendo a observação t da unidade observacional l .

Não sabemos o valor de λ , m e d . Beyaert e Camacho (2008) solucionam este problema inferindo apropriados valores a estes parâmetros. Tome $\hat{\varepsilon}_{\theta_0}$ como o vetor de resíduos do modelo (22) e defina a soma dos quadrados dos resíduos como $S_{\theta_0} = \frac{1}{T} \hat{\varepsilon}'_{\theta_0} \hat{V}_0 \hat{\varepsilon}_{\theta_0}$.

Como S_{θ_0} é um função de θ_0 , desta forma, estimar θ consiste em minimizar S_{θ_0} com respeito à θ_0 para encontrar:

$$\hat{\theta} \equiv [\hat{\lambda}, \hat{m}, \hat{d}] = \arg_{\theta_0} \min(s_{\theta_0}^2) \quad (27)$$

Substituímos estes valores em (22), aplicamos FGLS e encontramos o valor de $\hat{\beta}_{\hat{\theta}, FGLS}$.

O nome do procedimento utilizado por Camacho e Beyaert é conhecido como “grid-FGLS”, a saber:

Para cada busca para $m \in [1, 2, \dots, N]$ e cada $d \in [1, 2, \dots, p]$, λ é dado pelo valor de $(g_{m,\tau} - g_{m,\tau-d})$, para cada $\tau \in (1, 2, \dots, T)$.

A fração da amostra que esteja sob regime I é calculada. Se esta fração pertencer a intervalo $[\pi_l, 1 - \pi_l]$ as estimativas de β_θ e S_{θ_0} são computadas. Caso não, a combinação de m , d e λ são descartadas e o procedimento busca um novo ponto para o vetor θ . O processo de estimação é finalizado quando da obtenção de $\hat{\theta}$ e seu correspondente $\hat{\beta}_{\hat{\theta}, FGLS}$.

Dado o procedimento descrito acima, basta saber se este modelo é superior ao de Evans-Karras. Se sim, devemos testar se há convergência. E, se existir convergência, testar se é absoluta ou condicional. Estes testes serão explicados a seguir.

3.3. Modelo Linear versus Modelo não-linear com variável Threshold

A hipótese a ser testada, agora, é que o modelo linear é superior ao modelo com variável *threshold*. O problema é que os parâmetros m , d e λ não são identificados na hipótese nula de linearidade, o que impossibilita o uso dos testes de restrições de Wald, do Multiplicador de Lagrange e o Razão de Verossimilhança. Este problema não é tão incomum nos estudos de modelo TAR. A melhor solução, conforme Beyaert e Camacho (2008) seria recorrer, mais uma vez, as simulações de *bootstrap*.

Para início, estima-se o modelo linear por FGLS e o modelo de Beyaert-Camacho por “grid-GLS”. Para cada modelo, computa-se a função de verossimilhança para o ponto de estimação de cada modelo, L_1 e L_2 , respectivamente, e encontra-se, $\mathcal{L}_{1,2} = -2 \ln (L_1/L_2)$.

A hipótese nula é rejeitada se $\mathcal{L}_{1,2}$ for muito grande. Para o teste, Beyaert e Camacho (2008) fizeram uma adaptação do procedimento realizado por Caner e Hansen (2001) com simulações *bootstrap* para modelos com única equação.

Como não sabemos se há ou não raiz unitária, temos que fazer dois tipos de simulações *bootstrap* para o modelo de Evans-Karras. A primeira simulação seria o modelo de Evans-Karras sem restrição. A segunda seria o modelo Evans-Karras com a suposição da série possuir raiz unitária, isto é, $\rho_n = 0$. Sendo assim, o modelo seria:

$$\Delta g_{n,t} = \delta_n + \sum_{i=1}^p \varphi_{n,i} \Delta g_{n,t-i} + \varepsilon_{n,t} \quad (28)$$

O valor crítico é obtido pelas simulações de *bootstrap* para o formato sem restrição da seguinte maneira: primeiro, estima-se o modelo linear de Evans-Karras por FGLS e encontramos:

$$e_{n,t}^L = \Delta g_{n,t} - \hat{\delta}_n + \hat{\rho}_n g_{n,t-1} + \sum_{i=1}^p \hat{\varphi}_{n,i} \Delta g_{n,t-i} \quad (29)$$

Para todos n e t . Reorganizando os distúrbios de forma similar ao da matriz E^o , encontramos:

$$\tilde{E} = \begin{bmatrix} e_{1,1}^L & e_{2,1}^L & \cdots & e_{N,1}^L \\ e_{1,2}^L & e_{2,2}^L & \cdots & e_{N,2}^L \\ \vdots & \vdots & \cdots & \vdots \\ e_{1,T}^L & e_{2,T}^L & \cdots & e_{N,T}^L \end{bmatrix} \quad (30) \quad (37)$$

As linhas de \tilde{E} são mescladas de forma que gere uma nova série $\{e_{n,t}^*, n = 1, \dots, T\}$ para $t = 1, \dots, N$ que preserve a correlação contemporânea dos erros.

Utilizando a série $e_{n,t}^*$, n , e as estimativas dos parâmetros encontradas por GLS, novos valores são simulados para a variável dependente.

$$\Delta g_{n,t}^* = \hat{\delta}_n + \hat{\rho}_n g_{n,t-1}^* + \sum_{i=1}^p \hat{\varphi}_{n,i} \Delta g_{n,t-i}^* + e_{n,t}^* \quad (31)$$

Análogo a estatística $\mathcal{L}_{1,2} = -2 \ln(L_1/L_2)$, computamos $\mathcal{L}_{1,2}^*$ para cada uma das simulações. Neste estudo, faremos 1000 replicações. O p-valor de *bootstrap* é o percentual de vezes que $\mathcal{L}_{1,2}^*$ é menor que a estatística inicial para os dados observados.

Para o modelo com restrição:

$$e_{n,t}^{L,r} = \Delta g_{n,t} - \hat{\delta}_n^{(r)} + \sum_{i=1}^p \hat{\varphi}_{n,i}^{(r)} \Delta g_{n,t-i} \quad (32)$$

O algoritmo *bootstrap* é semelhante ao modelo irrestrito. Porém, desta vez os valores simulados para a variável dependente serão da seguinte forma:

$$\Delta g_{n,t}^{*(r)} = \hat{\delta}_n^{(r)} + \sum_{i=1}^p \hat{\varphi}_{n,i}^{(r)} + \Delta g_{n,t-i}^{*(r)} + e_{n,t}^{*(r)} \quad (33)$$

Sabedor dos dois resultados, modelo restrito e irrestrito, é escolhido para superar o Beyaert-Camacho, o modelo de Evans-Karras que apresentar o resultado mais conservador, ou seja, maior p-valor *bootstrap*. Se o modelo TAR for adotado, devemos testar se há convergência ou não.

3.4. Testes de Convergência para o modelo Beyart-Camacho

As hipóteses a serem testadas para suposição de convergência no modelo com variável limiar são:

- a) $H_{0,2} : \rho_n^I = \rho_n^{II} = 0 \forall n,$
- b) $H_{A,2_a} : \rho_n^I < 0, \rho_n^{II} < 0 \forall n,$
- c) $H_{A,2_b} : \rho_n^I < 0, \rho_n^{II} = 0 \forall n,$
- d) $H_{A,2_c} : \rho_n^I = 0, \rho_n^{II} < 0 \forall n,$

A hipótese nula *a* significa ausência de convergência nos regimes I e II. A hipótese alternativa *b* significa convergência nos regimes I e II. A hipótese alternativa *c* expressa convergência apenas no regime I e a hipótese *d* denota convergência apenas no regime II.

Vale lembrar que as propriedades de ρ são as mesmas para todas as observações. Assim como um país, no nosso caso um estado, não converge para outro país, nenhuma outra série pode ser $I(0)$. Desta forma, as séries $g_{n,t}$ do painel são todas $I(0)$ ou são todas $I(1)$.

Beyaert e Camacho (2008) estenderam metodologia de Caner e Hansen (2001) para equações simples para dados em painel. Esta metodologia propõe um teste embasado no critério de Wald contra a hipótese alternativa. Para dados em painel, a estatística para testar a convergência global seria:

$$R_2 = t_I^2 + t_{II}^2 \quad (34)$$

Onde t_I e t_{II} são as estatísticas-t com respeito aos regimes I e II do modelo não-linear com variável limiar. Isto é, se $\hat{\rho}_n^I$ corresponde a estimativa de ρ_n^I do regime I. A estatística t_I seria :

$$t_I = \frac{\hat{\rho}_n^I}{s_{\rho_n^I}} \quad (35)$$

O raciocínio é equivalente para o regime II.

Como R_2 corresponde à hipótese b , valores altos de R_2 levam aceitar a hipótese de convergência global.

É fácil ver que para a hipótese de convergência no regime I, deve-se usar t_I , enquanto que para a hipótese de convergência no regime II, deve-se usar t_{II} . Desta maneira, um valor absoluto alto para t_I indica presença de convergência no regime I, enquanto que um alto t_{II} sugere convergência no regime II.

Mais uma vez, recorreremos às simulações de *bootstrap*. Os primeiros passos para realizar a simulação são equivalentes a simulação feita para o modelo linear com restrição (28), até encontrar uma matriz similar a \tilde{E} .

A preferência ao modelo linear para a simulação é justificada por Beyaert e Camacho (2008) por dois motivos. O primeiro é que a geração de dados para variável dependente pelo modelo linear é muito mais simples que pelo o modelo não-linear com variável limiar em que a variável de transição é endógena. O segundo é por

conta de uma recomendação feita por Caner e Hansen (2001), na qual diz que os resultados obtidos pela simulação do modelo linear são estatisticamente mais significativos do que os resultados encontrados pelo modelo não-linear com variável limiar.

Para finalizar os testes de convergência, devemos classificar crescentemente as estatísticas de testes R_2 , t_I e t_{II} . Vale ressaltar que o percentual dos testes realizados para a estatística R_2 que estiverem à direita do R_2 dos dados amostrais observados será o p-valor de *bootstrap* para a hipótese alternativa b . Enquanto que os p-valores das hipóteses alternativas de c e d serão o percentual de vezes que t_I e t_{II} das simulações estiverem, respectivamente, a esquerda de t_I e t_{II} para os dados observados.

Se existir convergência, devemos testar se esta é absoluta ou condicional. Para o nosso modelo, a convergência absoluta significaria que o P_0 entre os estados seguem para o mesmo estado estacionário. Já a convergência condicional significaria que os estados caminham para estados estacionários diferentes.

Supondo convergência para o modelo de Beayert-Camacho, $\rho_n^i < 0, \forall n = 1, \dots, N$ e $i = I, II$, a hipótese para convergência absoluta em ambos os regimes será:

$$\delta_n^i = 0, \forall n = 1, \dots, N, i = I, II \quad (36)$$

A hipótese para convergência absoluta somente no regime I será:

$$\delta_n^I = 0, \forall n = 1, \dots, N \text{ e } \delta_n^{II} \neq 0, \forall n = 1, \dots, N \quad (37)$$

A hipótese para a convergência absoluta somente no regime II será:

$$\delta_n^{II} = 0, \forall n = 1, \dots, N \text{ e } \delta_n^I \neq 0, \forall n = 1, \dots, N \quad (38)$$

A hipótese para convergência condicional em ambos os regimes será:

$$\delta_n^i \neq 0, \forall n = 1, \dots, N, i = I, II \quad (39)$$

Beayert e Camacho (2008) propõem testes baseados na estimação por grid-GLS do modelo com variável limiar. Essas estatísticas de testes são uma expansão do proposto por Evans e Karras (1996). As estatísticas são:

$$\Phi_a = \frac{1}{2N-1} \{ \sum_{n=1}^N [t(\hat{\delta}_n^I)]^2 + \sum_{n=1}^N [t(\hat{\delta}_n^{II})]^2 + \} \quad (40)$$

$$\Phi_b = \frac{1}{N-1} \{ \sum_{n=1}^N [t(\hat{\delta}_n^I)]^2 \} \quad (41)$$

$$\Phi_c = \frac{1}{N-1} \{ \sum_{n=1}^N [t(\hat{\delta}_n^{II})]^2 \} \quad (42)$$

Dado a endogeneidade da variável de transição, os p-valores são novamente encontrados por *bootstrap* através do modelo linear com imposição da restrição $\delta_n = 0, \forall n = 1, \dots, N$. Estimamos então:

$$\Delta g_{n,t} = \rho_n g_{n,t-1} + \sum_{i=1}^p \varphi_{n,i} \Delta g_{n,t-i} + \varepsilon_t \quad (43)$$

Com $n = 1, \dots, N$ e $t = 1, \dots, T$, por FGLS. Novamente, as linhas da matriz dos resíduos são embaralhadas e os dados são gerados a partir das estimativas de (19). O modelo limiar é ajustado por estes dados e os testes Φ_a , Φ_b e Φ_c são computados.

Se a hipótese nula de divergência for rejeitada em relação à b , temos:

- Φ_a muito grande, caracteriza convergência condicional em ambos os regimes
- Φ_b muito grande e Φ_c pequeno, assinala convergência condicional no regime I e convergência absoluta no regime II.
- de forma análoga, Φ_c , muito grande e Φ_b pequeno assinala convergência condicional no regime II e absoluta no regime I.

Se a hipótese de divergência for rejeitada em favor de c , temos:

- Φ_b muito grande, caracteriza convergência condicional no regime I.
- Φ_b não tão grande, caracteriza convergência absoluta no regime I.

Se a hipótese de divergência for rejeitada em favor de d , temos:

- Φ_c muito grande, assimila convergência condicional no regime II.
- Φ_c não tão grande, assimila convergência absoluta no regime II.

3.5. Adaptações dos Modelos

Por mais que os modelos de Evans-Karras e Beyaert-Camacho possuam a renda *per capita* como variável e países como observações, a metodologia econométrica empregada neles permite uma generalização para outras variáveis econômicas e outras unidades observacionais. Esta substituição foi feita nesse trabalho.

As unidades observacionais, outrora países, passam a ser os estados brasileiros, enquanto que a variável de estudo passa a ser a proporção de pobres P_0 . Ou seja, em $\Delta g_{n,t}$ o nosso $g_{n,t}$ passa a ser $g_{n,t} = p_{0,n,t} - \overline{p_{0,t}}$. Onde, $p_{0,n,t} = \log(P_{0,n,t})$. Sendo $P_{0,n,t}$ a proporção de pobres para cada estado observado no tempo t e $\overline{p_{0,t}} = \frac{1}{N} \sum_{n=1}^N p_{0,n,t}$, isto é, a média *cross-sectional* da proporção de pobres no período t . Todas as outras características auto-regressivas dos parâmetros, tanto no modelo linear como no modelo TAR, ficam preservadas.

Quanto aos testes de convergência no modelo TAR, não contabilizamos os resultados do teste para ambos os regimes, uma vez que temos os resultados para o regime I e para o regime II, o que inclui toda a amostra.

4. Descrição dos dados e Índices de Pobreza

4.1. Base de Dados

A base de dados utilizada no presente trabalho foi extraída das PNADs (Pesquisa Nacional por Amostra de Domicílios) de 1977 a 2009. Estas PNADs fornecem, dentre uma gama de variáveis, a renda total domiciliar juntamente com o número de pessoas de cada domicílio. Para encontrar a renda *per capita* domiciliar basta dividir o primeiro pelo segundo.

Algumas considerações devem ser feitas sobre a base de dados, a saber, os estados em que conseguimos extrair a renda no período dessa análise foram: Piauí, Maranhão, Ceará, Rio Grande do Norte, Paraíba, Pernambuco, Alagoas, Sergipe, Bahia, Minas Gerais, Espírito Santo, Rio de Janeiro, São Paulo, Paraná, Santa Catarina, Rio Grande do Sul, Goiás, Mato Grosso, Mato Grosso do Sul e mais o Distrito Federal. Isto é, dezenove estados mais o Distrito Federal. A exclusão dos outros seis estados da federação (Tocantins, Pará, Amapá, Amazonas, Roraima, Rondônia e Acre) se deu unicamente pela indisponibilidade de dados.

Até 1980 não conseguimos extrair as rendas domiciliares para o estado de Mato Grosso do Sul, uma vez que este estado não era emancipado⁵ e fazia parte do estado do Mato Grosso. Para formar o painel, contornamos este problema replicando os dados encontrados para Mato Grosso em 1977, 1978, 1979 no estado Mato Grosso do Sul.

Até 1988, o estado de Tocantins era uma região de Goiás. A emancipação deste estado se deu com a Constituição de 1988⁶. Desta forma, os dados encontrados para o estado de Goiás de 1977 a 1988, são na verdade os dados para o estado de Goiás e para o estado de Tocantins que conhecemos hoje.

Existem alguns anos entre 1977 e 2009 que não conseguimos extrair dados. Para resolver este problema colocamos nos anos ausentes a média do ano anterior com o ano posterior. Os anos que não conseguimos dados foram 1980, 1983, 1986, 1991, 1994 e 2000. Os anos de 1980, 1991 e 2000 são anos de censo. Em 1983 e 1986 os arquivos não possuíam todos os estados. Já no ano 1994 não houve PNAD.

A linha de pobreza escolhida foi a sugerida por Ferreira et al (2003), a linha é R\$ 131,97 para o ano de 1996. Todas as rendas foram deflacionadas para o ano de 1996. O deflator escolhido foi o INPC (Índice Nacional de Preços ao Consumidor)

4.2. Medidas de Pobreza.

Segundo o Banco Mundial (2001), pobreza é a privação do bem-estar. O conceito de bem-estar, contudo, envolve, além da renda, variáveis que indicam o estado de redes sociais na economia, tais como, saúde, habitação, meio-ambiente e educação, entre outras.

Deste modo, definir quem é pobre possui um caráter multidimensional e avaliar o nível de pobreza por índices unidimensionais, como a renda, pode, aparentemente, fornecer resultados artificiais.

Entretanto, a maioria dos estudos usa a renda como um indicador de bem-estar e conseqüentemente do nível de pobreza existente. A justificativa é que um nível de renda razoável fornece ao indivíduo condições de ter suas necessidades básicas atendidas, como exemplo, boa alimentação, moradia e educação de qualidade

4.2.1. Linhas de Pobreza.

Por conta da carência de dados temporais para a construção de índices multidimensionais, escolheu-se trabalhar nesse estudo com um índice unidimensional da renda. Para construir índices unidimensionais da renda é estabelecida uma linha de pobreza que dividirá a população em estudo entre pobres e não-pobres. Esta linha de pobreza pode ser absoluta ou relativa.

Compreende-se por linha de pobreza absoluta aquela que é fundada de acordo com um valor monetário constante que contemple as necessidades básicas do indivíduo, sejam estas necessidades alimentares e não alimentares. Já a linha de pobreza relativa é aquela que situa a família ou o indivíduo em relação à sociedade. Por exemplo, podemos considerar como pobres o número de brasileiros que recebem menos de um quinto da renda per capita brasileira.

A definição do valor da linha de pobreza, seja ela absoluta ou relativa, dependerá do objetivo do pesquisador. É fácil ver que para a linha de pobreza absoluta, quanto menor o valor da linha de pobreza, maior o nível de indigência. Para a linha de pobreza relativa, por exemplo, quanto maior a divisão da renda per capita, maior o nível de indigência.

Esse trabalho elegeu uma linha de pobreza absoluta, haja vista que diferentes regiões podem refletir percentis de população diferente. Por exemplo, as características socioeconômicas da quinta parte da população mais pobre do Rio Grande Sul podem ser totalmente diferentes da quinta parte da população mais pobre da população do Piauí.

O valor da linha pobreza foi o desenvolvido por Ferreira et al. (2003). O trabalho de Ferreira et al. (2003) sugere três linhas de pobreza diferentes para o ano de 1996, todas embasadas nos gastos familiares com moradia, saúde, educação e alimentação (levando em conta o critério de necessidades calóricas mínimas para sobrevivência).

Estas linhas foram ordenadas crescentemente de forma que a primeira, R\$ 65, 07, representa mais uma linha de indigência. A segunda, R\$ 131, 97, foi desenvolvida pelo coeficiente de Engel, igualando a renda familiar a linha mínima de indigência e a terceira,

R\$ 204,05, seria uma linha de pobreza mais sofisticada. Como dito, a linha de pobreza escolhida para o presente trabalho foi a segunda, com o valor de R\$ 131,97.

5. Resultados

Como já citado anteriormente, no modelo de Evans-Karras quando uma única unidade observacional do grupo diverge, o resultado encontrado diz que toda a série não é $I(0)$, (BEYAERT, 2005).


Dessa forma, é aconselhável separar os estados em grupos em que as características sociais, econômicas e culturais sejam mais semelhantes, e, só depois, fazer a mesma análise com todos os estados juntos.

Dado os dezenove estados supracitados do nosso trabalho, o Nordeste brasileiro é a região que possui o maior número de estados com características semelhantes. Desta feita, separamos o Nordeste como o primeiro grupo e o restante dos países como o segundo grupo. Esta escolha não se limita somente a argumentos metodológicos, ela revela o anseio de saber se há convergência entre os estados nordestinos e a vontade de descobrir se há alguma convergência no restante do país que exclua a Nordeste.

Logo após esta divisão, aplicamos os mesmos testes para todas as unidades observacionais juntas. Ademais, segue os resultados dos testes precedidos pelos gráficos referentes a cada grupo.

5.1. Primeiro Grupo-Nordeste

Figura1: Resultados para a sub-amostra Nordeste



Fonte: elaborada pelo próprio autor.

Tabela 2: Resultados Sub-amostra Nordeste

Modelo Linear					
Divergência vs Convergência		Absoluta vs Condicional			
0, 2250 Divergência		-----			
Modelo com Variável Limiar					
Teste linear		Estado Transição	d	λ	Percentual sob Regime I
Irrestrito	Restrito				
0, 2050	0, 1510	Sergipe	1	-0, 0048	31,03%
Testes de Convergência					
Divergência vs Convergência		Absoluta vs Condicional			
Regime I 0, 6680	Regime II 0, 0340	Regime I	Regime II		
		0, 7240	0, 7770		

A análise gráfica mostra um declínio no P_0 em todos os estados nordestinos. Contudo, visualmente, não vemos uma diminuição na dispersão nos P_0 dos estados observados. Os testes de convergência para modelo linear de Evans-Karras evidenciam esta visualização ao não aceitar a hipótese de convergência. O p-valor da hipótese nula de divergência, 0, 2250, é maior do que o nível de significância 0,10 escolhido.

Como não devemos aceitar a hipótese de convergência no modelo linear, não iremos, portanto, analisar se esta é absoluta ou condicional.

Quanto aos testes de linearidade, para escolher entre o modelo com variável limiar ou não, temos que tanto o modelo linear irrestrito, como o restrito devem ser preferidos ao modelo TAR. O modelo linear irrestrito e o restrito possuem p-valor de 0, 2050 e 0, 1510, respectivamente, valores acima do 0, 10 aceitado para a hipótese nula de linearidade.

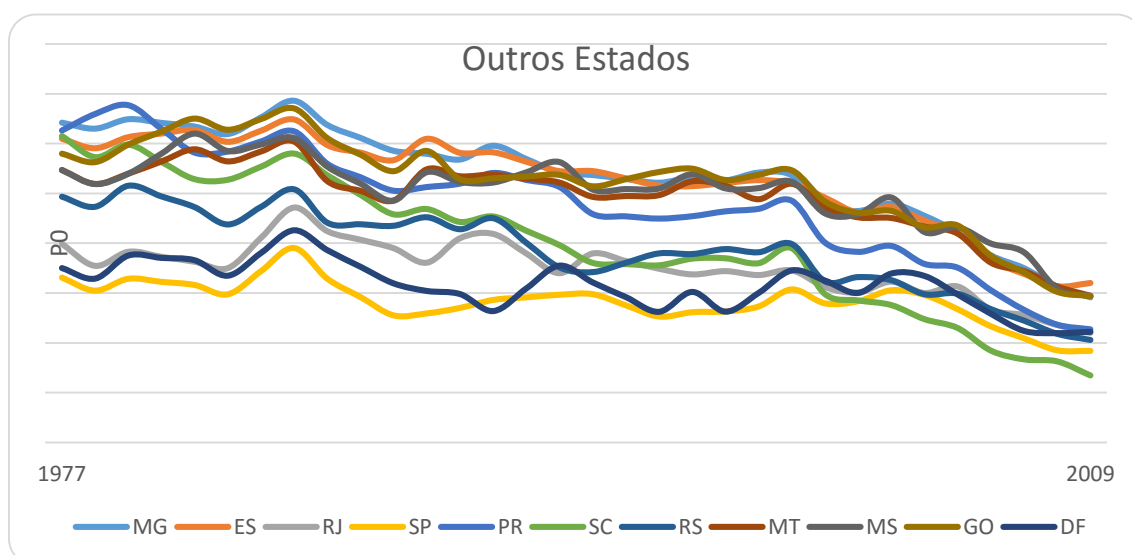
Para o modelo com efeito *threshold*, o estado de transição seria o Piauí. Neste modelo, a variável *threshold* seria a variação da evolução da proporção de pobres do Piauí em relação à média dos outros estados medida no período de um ano, com o valor limiar

de -0,0048. Todavia, como o modelo com efeito *threshold* foi preterido ao linear, não devemos ponderar estas considerações.

Assim, de acordo com a análise feita, devemos concluir que todos os estados nordestinos lidaram com uma redução do P_0 . Esta redução, porém, não foi acompanhada por um arrefecimento da dispersão entre estes estados. Os testes no modelo de Evans-Karras evidenciam isto ao não aceitarem a hipótese de convergência. Quanto ao modelo, devemos escolher o linear sem a presença de convergência como o que melhor explica a evolução do P_0 nos estados nordestinos.

5.2. Estados Não-nordestinos

Figura 2. Estados Não-nordestinos



Fonte: Elaborada pelo próprio autores

Com os outros estados mais o Distrito Federal, avaliamos se há um grupo de convergência no qual o Nordeste estaria fora. A análise gráfica nos mostra que, como nos estados nordestinos, há uma redução no P_0 destes outros estados mais o Distrito Federal. Notamos também que há uma redução da dispersão entre estes estados. Não se pode afirmar, contudo, se há redução ao ponto de existir convergência entre os estados.

Os testes de convergência na tabela 2 para ao modelo linear de Evans-Karras aceitam a hipótese nula de divergência, denunciando assim que estes estados não possuem convergência no modelo linear. Mais uma vez, por aceitar a hipótese nula de divergência, não vamos avaliar se a convergência no modelo linear seria absoluta ou condicional.

Tabela 2. Estados Não-nordestinos

Modelo Linear				
Divergência vs Convergência		Absoluta vs Condicional		
0,4575 Divergência		-----		
Modelo com Variável Limiar				
Teste linear		Estado Transição	λ	Percentua l sob Regime I
Irrestrito	Restrito			
0,1390	0,1590	Piauí	0,0 143	79,31%
Testes de Convergência				
Divergência vs Convergência		Absoluta vs Condicional		
Regi me I	Regi me II	Regime I	Regime II	
0,3210	0,0210	0,7920	0,3730	

Quanto ao modelo com efeito *threshold*, os primeiros testes a serem analisados são os testes de linearidade. Tanto o modelo linear irrestrito, quanto o modelo linear com restrição devem ser escolhidos em detrimento do modelo com variável limiar, haja vista que os dois possuem p-valor acima do nível de significância adotado de 0,10, 0,1390 e 0,1590, respectivamente. Desta forma, todos os resultados obtidos na análise do modelo com variável limiar não serão considerados.

A análise para os estados não-nordestinos nos mostrou que, assim como nos estados nordestinos, o nível de pobreza foi reduzido nos últimos anos. O melhor modelo para estes estados seria o linear. As estatísticas mostraram que não devemos aceitar a hipótese de divergência nesse modelo.

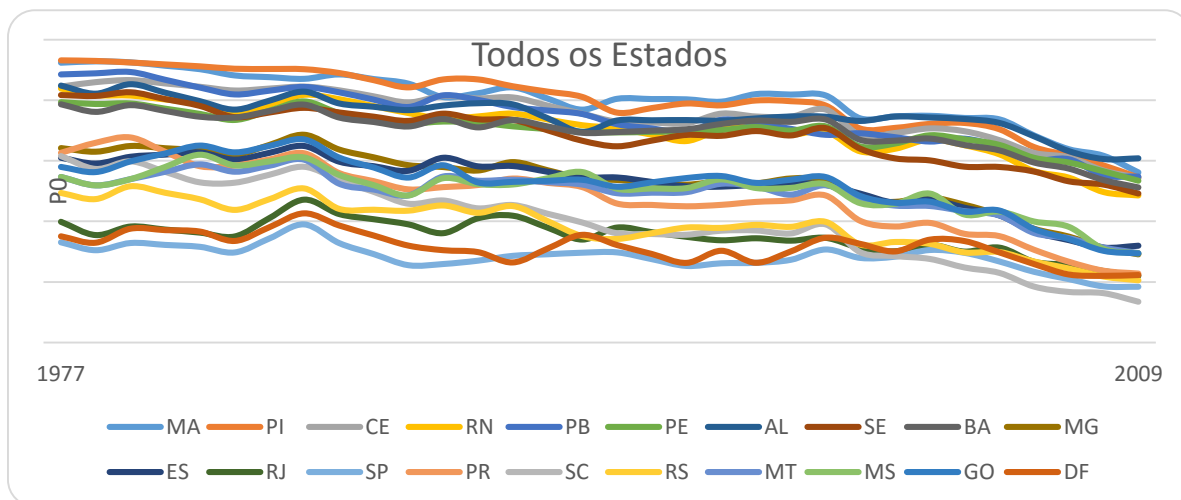
5.3. Brasil

A análise gráfica com todos os estados juntos nos mostra que, além da redução da pobreza vista anteriormente, a dispersão entre os dezenove estados mais o Distrito Federal diminuiu drasticamente no decorrer do tempo da análise. Basta, portanto, ver se esta redução na dispersão promove convergência entre os estados.

Os testes sobre o modelo linear mostram divergência, contudo os testes de linearidade mostram o modelo não-linear com variável limiar mais adequado do que o modelo linear, seja com a hipótese do modelo linear irrestrito, seja com a hipótese do modelo linear com restrição. Desta feita, fazemos a análise do modelo não-linear com efeito *threshold*.

Piauí é identificado como o estado cuja evolução determina a mudança dos regimes do modelo não-linear com variável limiar. O fato de Piauí ser o estado mais pobre no início da análise e ser, juntamente com o Maranhão, o estado que mais reduziu a pobreza no período da análise, deve justificar sua escolha perante os outros.

Figura 3. Todos os Estados



Fonte: Elaborado pelo autor.

Tabela 3: Resultados para amostra completa

Modelo Linear					
Divergência vs Convergência		Absoluta vs Condicional			
0, 3080		-----			
Divergência					
Modelo com Variável Limiar					
Teste linear					
Irrestrito	Restrito	Estado Transição	d	λ	Percentual sob Regime I
0, 0120	0, 0260	Piauí	2	-0,0151	34,48%
Testes de Convergência					
Divergência vs Convergência		Absoluta vs Condicional			
Regime I	Regime II	Regime I		Regime II	
0, 3680	0, 0040	0, 5060		0, 3290	
Convergência Absoluta					

Fonte: Elaborado pelo autor.

A evolução da taxa de variação do P_0 piauiense em relação à média entre grupos no período de dois anos é a variável *threshold* do modelo. Mais especificamente, quando a variação da taxa de evolução piauiense dos últimos dois anos for menor que a média explicitada em λ medida num período de dois anos, o modelo estará sob o regime I. Isto acontece em 34,48% da análise. Caso contrário, o modelo estará no regime II.

Os testes de convergência aplicados ao modelo com variável limiar, aceita fortemente a hipótese de convergência no regime II. O p-valor de 0, 0040 não nos permite

aceitar a hipótese nula de divergência. Desta feita, concluímos que em mais de 60% da amostra, todos os estados mais o Distrito Federal convergem no modelo especificado por Beyaert e Camacho (2008).

Os testes que investigam a natureza desta convergência concluem que as séries dos estados analisados convergem de forma absoluta no regime II. O p-valor de 0,3290 não nos permite descartar a hipótese nula de convergência absoluta no regime II. Os resultados obtidos para o formato da convergência no regime I devem ser ignorados, uma vez que a hipótese de divergência foi preferida a hipótese de convergência.

Convergir de forma absoluta significa que todos os estados da análise caminham para o mesmo estado estacionário. Sucintamente, concluímos que todos os estados mais o Distrito Federal possuíram um declínio real nos seus respectivos P_0 . Para análise temporal, observamos que o modelo não-linear com variável limiar é preferível ao modelo linear quando analisamos todos os estados juntos. No modelo não-linear com variável *threshold* há convergência entre estes estados de forma absoluta no regime II e o estado escolhido para representar a alternância entre os regimes foi o Piauí.

Temos visto nas últimas décadas políticas de combate a pobreza que abrange todo o país. O modelo não-linear com variável limiar mostra que, além da redução da pobreza, pode está havendo convergência absoluta entre os estados analisados. Ou seja, a pobreza está realmente menor, mas mais do que isto, os estados avaliados estão caminhando para a mesma proporção de pobres.

6. Considerações Finais

Este trabalho teve como objetivo principal buscar evidências empíricas para a hipótese de convergência de nível de pobreza entre os estados brasileiros. Para tanto, usou-se dois modelos de painel dinâmico: um auto-regressivo linear e um auto-regressivo não-linear com variável *threshold*.

As principais limitações do primeiro modelo, proposição de uniformidade na dinâmica de convergência e independência entre as unidades observacionais são ajustadas pelo segundo, o que torna o segundo modelo mais pujante que o primeiro e sua metodologia mais próxima da realidade.

O índice usado para mensurar a pobreza dos estados selecionados foi a proporção de pobres (P_0), que calcula o percentual de pobre para cada região selecionada. Foram selecionados 19 estados brasileiros mais o Distrito Federal, no período de 1977 a 2009.

Sob algumas restrições metodológicas e a hipótese que as semelhanças entre os estados nordestinos provocariam convergência entre eles, separamos estes estados e aplicamos os modelos. Do mesmo modo, sob a suspeita que outras regiões do Brasil (Região Sul, Sudeste e Centro-Oeste) caminham para um nível de pobreza comum, mas díspar do Nordeste, selecionamos os estados não-nordestinos e aplicamos os mesmos testes.

Os resultados empíricos recomendam o modelo linear em detrimento do não-linear como o mais apropriado para esses dois grupos de regiões. Quanto aos testes de

convergência, as estimativas encontradas não corroboram com a suposição que o Nordeste caminha para um nível de pobreza comum e nem que as outras regiões selecionadas no segundo grupo tendem para algum estado estacionário.

Os resultados obtidos significam que por mais que o nível de pobreza na região Nordeste venha se reduzindo nos últimos anos, a heterogeneidade entre os estados não permite assumir que há convergência entre eles. Interpretação idêntica deve ser feita para as outras regiões selecionadas.

Com o objetivo de analisar o Brasil como um todo, realizou-se os testes para todos os estados juntos. Os resultados foram bastante diferentes. Desta vez, o modelo não-linear com variável *threshold* foi escolhido como superior ao modelo linear. Os testes no modelo não-linear indicaram a presença de convergência absoluta em um dos regimes da amostra. A variável *threshold* selecionada foi o estado do Piauí.

A escolha do estado do Piauí como variável *threshold*, relaciona-se com o fato deste estado ser o mais pobre no início da amostra e o mesmo ter sido um dos que mais reduziu a pobreza nos anos em estudo.

Novamente, as interpretações sob estes resultados devem ser feitas com bastante prudência. A escolha do estado do Piauí como a variável *threshold* denota que a taxa de evolução da pobreza nesse estado é que vai definir em qual regime do modelo TAR estará a amostra. A vantagem do modelo possuir mais de um regime é que o modelo TAR pode conseguir identificar convergência, mesmo que esta exista em apenas um período da análise.

No modelo de Evans-Karras, para aceitar a convergência, esta tem que ser em todo o período da análise. Se assim não for, isto é, em algum período os estados deixarem de convergir, mesmo que seja por poucos anos, os testes não aceitam hipótese de convergência.

Convergência absoluta em um dos regimes no modelo não-linear, expressa que, em algum período da análise, os estados analisados convergem para o mesmo estado estacionário. Dessa forma, não podemos afirmar que a região Nordeste está caminhando para um nível de pobreza diferente do resto do Brasil, mas sim que as trajetórias dos estados brasileiros analisados os conduzem para mesmo nível de pobreza.

A fim de esclarecer, algumas observações devem ser feitas. O presente estudo analisa a dinâmica de convergência tendo em vista a proporção de pobres entre os estados. Este índice não leva em consideração a evolução da renda média dos estados. Mas sim, a quantidade de pessoas que está abaixo da linha pobreza escolhida.

Somente contabilizar o número de pessoas abaixo de um valor monetário, sem atribuir nenhum peso a suas distâncias para este valor, não nos permite auferir a intensidade e severidade da pobreza. Isto é, reduções expressivas no P_0 , não significa necessariamente, reduções na miséria e desigualdade de renda.

7. Notas

1. FGLS, *Feasible Generalized Least Squares*, ou Mínimos Quadrados Generalizados Viáveis.
2. SUR, *Seemingly Unrelated Regression*, ou equações de regressão aparentemente não relacionadas.
3. *Generalized Least Squares*, ou Mínimos Quadrados Generalizados.
4. A justificativa de se usar FGLS é análoga a do modelo de Evans-Karras.
5. O estado do Mato Grosso do Sul foi desmembrado do estado do Mato Grosso por lei complementar de 11 de outubro de 1977. O estado foi instalado em 1 de janeiro de 1979.
6. Tocantins passou a ser estado em 1 de janeiro de 1989.
7. O INPC está disponível no sítio do IPEADATA, a saber:
<http://www.ipeadata.gov.br/Default.aspx>

8. Referências Bibliográficas

BANCO MUNDIAL. **Chapter 1. The Concept of Poverty and Well-being.** World Bank, mimeo, 2001.

BANERJEE, A., DUFLO, A. In equality and growth: what can the data say? **Journal of Economic Growth.** V. 8, pp. 267-99, 2003.

BARROS, R. P.; HENRIQUES, R.; MENDONÇA, R. **A estabilidade inaceitável: desigualdade e pobreza no Brasil.** Texto para discussão, n ° 800, IPEA, 2001.

BARROS, R. P.; CARVALHO, M.; FRANCO, S. e MENDOÇA, R – **A queda recente da desigualdade de renda no Brasil.** Texto para Discussão, n ° 1258, IPEA, 2007.

BARROS, R. et al. – **Determinantes da Queda na Desigualdade no Brasil.** Texto para Discussão, n ° 1460, IPEA, 2010.

BEYAERT, Arielle. **Output Convergence: The Case of Current and Forthcoming Members of the European Union.** 2005.

BEYAERT, Arielle; CAMACHO, Maximo. **TAR Panel Unit Root Tests and Real Convergence: An Application to the EU Enlargement Process,** 2008

BOURGUIGNON, François – **The Poverty, Inequality and Growth Triangle**. Working Paper, World Bank, 2003.

CANER, M., HANSEN, B. E. Threshold Autoregression with a Unit Root. **Econometrica**, V. 69, n ° 6, pp. 1555-1596, 2001.

CARTER, M. R., BARRET, C.B. The economics of poverty traps and persistent poverty: An asset-based approach. **Journal of Development Studies**. V. 42:2, pp. 178-199, 2006.

CHAKRAVARTY, S.R, and MULIERE, P. **Welfare indicators: a review and new perspectives. II. Measurement of Poverty**, *Metron*. V. 62, 2003.

COELHO, R. L. P.; FIGUEIREDO, L. Uma análise da hipótese da convergência para os municípios brasileiros. **Revista Brasileira de economia**. V. 61, pp. 331-352, 2007.

DICKEY, D. A. e FULLER, W.A. “Distribution of the Estimators for Autoregressive Time Series with a Unit Root,” **Journal of the American Statistical Association**, V. 74, pp. 427-431, 1979.

DOLLAR, D. e KRAAY, Aart – Growth is Good for the Poor. **Journal of Economic Growth**. V. 7, 2002.

ELLIOTT, G., ROTHENBERG T. J., e STOCK J.H. Efficient Tests For an Autoregressive Unit Root. **Econometrica**. V. 64, pp: 813-836, 1996.

EVANS P.; KARRAS, G. Convergence revisited. **Journal of Monetary Economics**. V. 37, pp. 249-265, 1996.

EVANS, P. Using Cross-Country Variance to Evaluate Growth Theories. **Journal of Economic Dynamics and Control**. V. 20, pp.1027-1049, 1996.

FERREIRA, F. et all. - A Robust Poverty Profile for Brazil using Multiple Data Sources, **Revista Brasileira de Economia**. V.57 , n ° 1, 2003.

FERREIRA, R. T., VIEIRA, G. C. Clubes de Convergência de Renda na América: uma Abordagem através de Painel Dinâmico Não-linear. Em: ENCONTRO DA ANPEC, 2009, Foz do Iguaçu. **Anais...** Foz do Iguaçu, 2009. Disponível em: <<http://www.anpec.org.br/encontro2009/inscricao.on/arquivos/000-e287725689cd2c9d74658422ab604271.pdf>> Acesso em: 2010.

FIELDS, G. S. **Distribution and development: a new look at the developing world.** [S.l.]: Russell Sage Foundation and the MIT Press, 2001.

FOSTER, J. E., GREER, J. e THORBECKE, E. A Class of Decomposable Poverty Indices. **Econometrica**. V. 52, pp.761-766, 1984.

GONDIN, J.L; BARRETO, F. A., CARVALHO, J. R. - Condicionantes de Clubes de Convergência no Brasil. **Revista Estudos Econômicos**, v. 37, n ° 1, 2007.

HOFFMANN, R. Elasticidade da pobreza em relação à renda média e à desigualdade no Brasil e nas Unidades da Federação. **Revista Economia**, jul. 2005.

HOFFMAN,R. Transferências de renda e redução da desigualdade no Brasil e cinco regiões entre 1997 1 2004. **Econômica**. Rio de Janeiro.V.8, n.1, pp. 55-81, 2006.

IM, K.S., M. H. PESARAN, e Y. SHIN. “Testing for Unit Roots in Heterogeneous Panels”, *Manuscript*, Trinity College, Cambridge,1997.

KUZNETS, S. Economic growth and income inequality. **American Economic Review**.V. 45, n. 1, pp. 1-28, 1955.

KWAITKOWSKI D., PHILLIPS P.C.B., SCHMIDT, P., SHIN, Y. How Sure are We that Economic Time Series Have a Unit Root? **Journal of Econometrics**. V. 54, pp.159-178, 1992.

LEVIN, A. e C. F. LIN. **Unit Root Tests in Panel Data: Asymptotic and Finite**

Sample Properties. N ° 92-93. 1993.

MADDALA, G., e WU, S. A comparative study of unit root tests with panel data and a new simple test. **Oxford Bulletin of Economics and Statistics.** V. 61, pp. 631-652, 2004.

MANSO, C. A., BARRETO, F. A. F. D., TEBALDI, E. O desequilíbrio regional brasileiro: novas perspectivas a partir das fontes de crescimento pró-pobre. **Revista Econômica do Nordeste**, v.31, n.13, 2006.

MOSSI, M. B., AROCA, P., FERNANDÉZ, I. J., AZZONI, C. R. Growth dynamics and space in Brazil. **International Regional Science Review.** V. 26, n ° 3, pp. 393-418, jul. 2003.

NERI, M. – **A nova Classe Média**, Rio de Janeiro, FGV/IBRE, 2008.

PHILLIPS, P. C. e PERRON P., “Testing for a Unit Root in Time Series Regression,” **Biometrika**, 75: 335-346, 1988.

RAJ, B., SLOTTJE, D. J. The Uncertain Unit Root in the U.S. Poverty Rate. **Empirical Economics.** V.22 pp. 555-570, 1997.

RAMOS, L. A desigualdade de rendimentos do trabalho no período pós-Real: o papel da escolaridade e do desemprego. **Economia Aplicada.**V.11, n° 2, 2007.

RAVALLION, M. Can high-inequality developing countries escape absolute poverty? **Economic Letters.** V. 56. 1997.

SACHSIDA, A. et al - **Um Estudo Sobre Retorno em Escolaridade no Brasil**, *Revista Brasileira de Economia.*V 58 n° 2, 2004.

SILVEIRA, R. N., Azzoni, C. R. Location and regional income disparity dynamics: The Brazilian case. **Papers in Regional Science.** V. 85, n °4, pp. 599–613, 2006.

SILVEIRA NETO, R. M. Quão pró-pobre tem sido o crescimento econômico no Nordeste?: evidências para o período 1991-2000. **Revista Econômica do Nordeste**, Dezembro, 2005.

SILVEIRA, F. G. et al. **Dimensão, magnitude e localização das populações pobres no Brasil**. Texto para Discussão, n ° 1278, IPEA, 2007.

SOARES, S. S. D., **O ritmo de queda na desigualdade no Brasil é adequado? Evidências do contexto internacional**. Texto para Discussão, n ° 1339, IPEA, 2009.

TROMPIERI, N. N.; LINHARES, F. C.; CASTELAR, L. I. M.. Convergência de renda dos estados brasileiros: uma abordagem em painel dinâmico com efeito threshold. Em: ENCONTRO DA ANPEC, 2008, Salvador. **Anais...** Salvador, 2008. Disponível em: <www.anpec.org.br/encontro2008/artigos/200807212130050-.pdf>. Acesso em: 2010.

WANG, B., DAYANANDAN, A. Unit Root Tests of Canadian Poverty Measures **Economics Bulletin**. V. 9, n. 2 pp. 1-7, 2006.

WHITE, H., ANDERSON, A. Growth vs. redistribution: does the pattern of growth matter?. **DFID white paper on eliminating World Poverty: making globalization Work for the Poor**, 2000.

ZIVOT, E., ANDREWS, D. W. K. Further Evidence on the Great Crash, the Oil-Price Shock, and the unit-Root Hypothesis, **Journal of Business and Economic Statistics**. V.10, pp.251-270, 1992.