r b e
REVISTA BRASILEIRA DE ECONOMIA
DOI 10.5935/0034-7140.20200007
ISSN 1806-9134 (online)
FGV
FUNDAÇÃO GETULIO VARGAS

Retorno Salarial do *Overeducation*: Viés de Seleção ou Penalização ao Excesso de Escolaridade?

Ana Cláudia Annegues[*]
Wallace Patrick Santos de Farias Souza[†]

Sumário

1. Introdução 119
2. *Overeducation*: Teoria e Evidência Empírica 122
3. Estratégia Empírica 124
4. Dados 127
5. Resultados 131
6. Considerações Finais 135

Palavras-chave
Overeducation, salário, viés de seleção

JEL Codes
I20, J31, C23

Resumo • Abstract

This paper investigates the wage effects of overeducation, a situation where workers perform jobs with lower required education. For this, data from graduates of the Federal University of Paraíba from 2003 to 2013 were used. The estimation of an OLS with fixed effects of individuals and firms, plus their interactions with time as a way to capture time varying unobserved factors, showed that overeducated graduates earn on average a lower salary than their peers with good match between education and occupation. Quantile regression showed that this effect penalizes more severely individuals in the higher quantiles of wage distribution, weakening the hypothesis that links overeducation to lower skill levels.
menores níveis de habilidade.

1. Introdução

A sobreeducação, em inglês *overeducation*, é o fenômeno no qual trabalhadores desempenham funções que exigem um grau de instrução inferior à possuída por estes. Na sua origem está a expansão da oferta de trabalhadores qualificados, grande parte com ensino superior, não acompanhada pelo crescimento em mesma proporção da demanda no mercado de trabalho, gerando perfis de trabalhadores além ou aquém do requerido.

Nas últimas décadas a literatura tem se empenhado em compreender as causas e as consequências do *overeducation*, embora não apresente uma teoria unânime sobre

[*]Pós-doutoranda do Programa de Pós-Graduação em Economia do Centro de Ciências Sociais Aplicadas, Universidade Federal do Rio Grande do Norte (PPECO/CCSA/UFRGN). Av. Senador Salgado Filho, 3000, Lagoa Nova, Natal, RN, CEP 59072-970, Brasil. 0000-0001-6656-3824

[†]Programa de Pós-Graduação em Economia, Departamento de Economia, Universidade Federal da Paraíba (PPGE/DE/UFPB). Via Expressa Padre Zé, 289, Castelo Branco III, João Pessoa, PB, Brasil. 0000-0002-0598-936X

annegues.ana@gmail.com wpsfarias@gmail.com

This is an open-access article distributed under the terms of the Creative Commons Attribution License.

Recebido em 02 de outubro de 2019
Aceitação final em 11 de dezembro de 2019

o tema. Segundo Groot (1996), dentre as consequências do *overeducation* estão a subutilização do estoque de capital humano e, consequentemente, a ineficiência dos gastos públicos em educação

Parte significativa das pesquisas empíricas existentes se dedica a analisar as consequências em termos salariais para os trabalhadores *overeducated* (como Bauer, 2002, Sicherman, 1991, and McGuinness, 2006). Em geral os resultados encontrados apontam para uma redução nos rendimentos desses trabalhadores com relação aos seus pares corretamente alocados no mercado.

O procedimento adotado por estes trabalhos consiste em estimar uma equação minceriana (Mincer, 1974) de salários acrescentando o excesso de anos de estudos com relação ao que é requerido ou uma variável *dummy* indicando se o indivíduo está ou não em *overeducation*. Entretanto, tais abordagens empíricas enfrentam o mesmo desafio imposto às análises tradicionais de retorno da educação: o controle da heterogeneidade não observada entre os indivíduos. Isso implica em identificar se os trabalhadores *overeducated* auferem um salário menor pelo excesso de qualificação ou por fatores não observados que levam o trabalhador a viver esse status. Sendo assim, são necessárias estratégias que lidem com esse viés de seleção.

Boa parte das pesquisas iniciais sobre o impacto salarial do *overeducation* utilizam apenas dados em *cross-section*, o que dificulta o controle da heterogeneidade não observada e pode resultar em estimativas tendenciosas caso haja correlação entre habilidades inatas e *overeducation*. Chevalier (2003), embora utilize dados de corte, tenta incluir as habilidades não observadas explicitamente no modelo utilizando os resíduos da equação minceriana tradicional como *proxy*. Já Bauer (2002) procura fazer esse controle com dados em painel e estimação com efeitos fixos, o que permite o controle de características não observadas fixas no tempo.

No entanto, o viés surge também da existência de não observáveis variantes no tempo e somente o controle dos efeitos fixos pode ser insuficiente para fornecer estimativas robustas. A existência de habilidades que mudam com o tempo é uma hipótese razoável, principalmente se considerarmos o argumento levantado por alguns autores (Duncan & Hoffman, 1981; Sicherman, 1991; Cohn & Ng, 2000) de que o *overeducation* pode ser uma maneira informal de aquisição de capital humano; através da vivência do mercado de trabalho, o indivíduo pode adquir habilidades que não são repassadas nos cursos universitários. Uma alternativa para controlar esses fatores seria encontrar uma variável instrumental para o *overeducation*, o que não é uma tarefa trivial.

McGuinness (2006) afirma que as metodologias de Chevalier (2003) e Bauer (2002) ainda ignoram os potenciais impactos salariais de componentes não observados. Para testar se o *overeducation* se origina de um déficit de habilidade por parte dos indivíduos, o autor parte da hipótese de que a localização do indivíduo na distribuição de salários reflete o seu nível de habilidade relativa, de modo que indivíduos mais habilidosos tendem a ocupar posições mais elevadas na distribuição. A equação minceriana é estimada, então, via Regressão Quantílica; assim, é possível quantificar a redução de salário que trabalhadores *overeducated* sofrem com relação aos corretamente alocados com mesmo nível de habilidade. Se o *overeducation* reduz mais fortemente o salário dos trabalhadores menos habilidosos, é um indício de que as habilidades não observadas

desempenham um papel importante na situação de excesso de qualificação desses indivíduos.

Dito isso, o presente artigo objetiva mensurar o impacto do *overeducation* sobre os salários dos indivíduos com ensino superior empregando ferramentas para contornar os problemas de autosseleção. Consideramos um modelo empírico com especificação semelhante à equação minceriana de salários, incluindo uma *dummy* para os indivíduos *overeducated*. Primeiramente, procedemos à estimação de um modelo de dados em painel com dois efeitos fixos, relacionados ao trabalhador e à firma na qual o mesmo trabalha. Aqui queremos incluir também características não observadas das empresas que podem impactar o salário.

Dada a dificuldade de encontrar instrumentos adequados para o *overeducation*, a estratégia adotada para controlar a parcela dos fatores omitidos que são variantes no tempo é inspirada no trabalho de Baltagi, Egger, e Pfaffermayr (2014) da literatura de comércio internacional a qual consiste na inclusão de *dummies* para interações entre trabalhador e ano e interações entre empresa e ano. A utilização da dimensão de tempo fornece a variação de características não observadas dos trabalhadores e das firmas entre os anos, proporcionando uma aproximação das não-observáveis *time-varying*. A estimação do modelo é feita via *Ordinary Least Squares* (OLS) para dados em painel com mais de duas dimensões. Esse método foi desenvolvido por Carneiro, Guimarães, e Portugal (2009) e aperfeiçoado computacionalmente por Guimarães e Portugal (2009).

Mesmo com as interações como *proxies* de fatores variantes no tempo, queremos ainda investigar quais os papeis da habilidade não observada e do *overeducation* na determinação dos salários. Para tanto, tal qual McGuinness (2006), estimamos a equação minceriana por Regressão Quantílica. Caso o *overeducation* reduza os salários dos trabalhadores em diferentes quantis em proporção semelhante, pode-se lançar dúvida sobre a hipótese que liga o *overeducation* exclusivamente às diferenças de habilidade. Além disso, a regressão quantílica permite visualizar os diferentes impactos do excesso de qualificação em diferentes níveis de salários.

Serão utilizados dados de egressos da Universidade Federal da Paraíba (UFPB), fornecidos pela Superintendência de Tecnologia da Informação (STI) na universidade, entre os anos de 2003 e 2013. Através do Cadastro de Pessoa Física (CPF), foi possível mapear a situação desses ex-alunos na Relação Anual de Informações Sociais (RAIS), identificando as suas ocupações em cada ano, segundo a Classificação Brasileira de Ocupações de 2002 (CBO 2002). Na CBO são definidos os graus de instrução necessários a cada ocupação, o que permite saber se o egresso está ou não *overeducated*.

Os dados foram agrupados em seis janelas de seis anos (2003–2008, 2004–2009, 2005–2010, 2006–2011, 2007–2012, 2008–2013).[1] Essa divisão foi feita para evitar a perda de observações que ocorreria caso analisássemos somente os índivíduos permanecentes na amostra durante todo o período 2003–2013. A saída do índivíduo (atrito), se ocorrida de forma não aleatória, pode implicar em mais uma fonte de heterogeneidade não observada.

O artigo encontra-se dividido da seguinte forma: a seção 2 contém uma revisão teórica e da literatura empírica do overeducation; na seção 3 tem-se os procedimentos

[1] Procedimento semelhante foi empregado por Schank, Schnabel, e Wagner (2010), que investigaram a existência de viés de seleção nos maiores salários pagos por firmas exportadoras

metodológicos; na seção 4 a descrição da base de dados; na seção 5 os resultados encontrados; e na seção 6 as considerações finais.

2. *Overeducation*: Teoria e Evidência Empírica

Até o momento, a literatura tem interpretado o *overeducation* sob a ótica de algumas teorias sobre educação e mercado de trabalho, como a teoria do capital humano (Becker, 1962, e Schultz, 1961), os modelos de competição por emprego (Thurow, 1975) e os assignment models.

Segundo a teoria do capital humano (ver Becker, 1962, e Schultz, 1961), os salários dos trabalhadores são determinados pela sua produtividade, a qual depende do seu estoque de capital humano adquirido pela educação formal e pela experiência. Nesse sentido, o *overeducation* pode ser considerado uma exceção à teoria do capital humano por originar-se de um desequilíbrio entre oferta e demanda no mercado de trabalho. A consistência da teoria do capital humano, frente à ocorrência de *overeducation*, seria possível caso o *overeducation* fosse comprovadamente um fenômeno de curto prazo, onde o mercado naturalmente se encarregaria de corrigir os desajustes entre trabalhadores e firmas.

Sob a perspectiva dos modelos de competição por emprego (Thurow, 1975), o excesso de educação formal seria uma consequência da competição entre os trabalhadores pelos postos de trabalho. A rigidez da demanda por trabalhadores qualificados levaria estes a acumularem mais anos de estudo, em alguns casos mais do que o necessário para uma determinada ocupação. Embora o aumento da oferta de trabalhadores qualificados reduza o retorno à escolaridade, o investimento em educação não diminui, dado que este assegura a posição do trabalhador na competição pela vaga de trabalho. Além disso, os trabalhadores podem permanecer em empregos para os quais são *overeducated* com vistas a adquirir a habilidade necessária para conseguir uma ocupação adequada ao seu grau de instrução (Sicherman, 1991). Nessas condições, o *overeducation* tende a se tornar uma condição permanente aos indivíduos, contrapondo a tese levantada pela teoria do capital humano de que se trataria de um fenômeno de curto prazo.

Uma explicação alternativa, a qual seria um meio termo entre as duas hipóteses levantadas anteriormente, é fornecida pelos *assignment models*. No geral, esses modelos pontuam que a distribuição de salários entre os trabalhadores é um reflexo do processo de alocação de trabalhadores heterogêneos à diferentes tipos de ocupações. Sattinger (1993) mostra que essa desigualdade veio se reforçando ao longo do tempo e a explicação para isso está relacionada não só à qualificação, mas também depende da disponibilidade e/ou qualidade dos empregos (McGuinness, 2006). A partir do momento que há um desencontro entre a distribuição de empregos segundo às exigências de habilidade e a distribuição de trabalhadores segundo os níveis de educação, alguns trabalhadores acabam em trabalhos para os quais estão sobreeducados (Kiersztyn, 2013).

Os primeiros estudos empíricos a respeito do descasamento entre grau de instrução possuído e grau de instrução requerido surgem nos anos 70 nos Estados Unidos, com os estudos de Freeman (1976) e Smith e Welch (1978), quando se torna iminente a preocupação com o excesso de oferta de trabalhadores qualificados daquele país.

Dentre os determinantes micro e macroeconômicos do *overeducation* comumente analisados pela literatura se destacam as características individuais, como idade e gênero, as condições do mercado de trabalho e a taxa de desemprego da economia. Morano (2014) testa a influência de inúmeros desses determinantes sobre a probabilidade de um trabalhador se encontrar em uma situação de *overeducation*, utilizando dados do mercado de trabalho da Itália. Com relação à idade, os autores encontram que os trabalhadores mais jovens são mais propensos à ocupar postos de trabalho não condizentes com seu grau de instrução. Este resultado confirma o consenso geral existente na literatura de que a qualidade do ajuste entre instrução e ocupação aumenta com a idade do individuo. Algumas teorias sobre mobilidade na carreira preveem que as habilidades adquiridas durante a situação de *overeducation* podem aumentar a probabilidade de ser promovido, de modo que ser *overeducated* seria uma estratégia ótima no início da carreira (Leuven & Oosterbeek, 2011).

Além dos atributos individuais e das condições macroeconômicas, uma parte importante da literatura tem sugerido que o *overeducation* consiste em um fenômeno mais comum em determinadas áreas de formação. As áreas ligadas a ciências e tecnologia podem fornecer maiores níveis de "habilidades produtivas" do que as áreas de humanidades, pois o currículo desses cursos enfatizam mais a aquisição de habilidades específicas requeridas pelas ocupações no mercado de trabalho (Reimer, Noelke, & Kucel, 2008).

Tal hipótese vem sendo corroborada pelas evidências empíricas. Dolton e Vignoles (2000) e Dolton e Silles (2008) analisaram os determinantes do *overeducation* no mercado de trabalho entre indivíduos graduados no Reino Unido. Ambos os trabalhos encontram que trabalhadores formados nas áreas de humanidades e artes apresentaram maior probabilidade de estarem sobreeducados em comparação com outros campos de estudo

Duncan e Hoffman (1981) foram os pioneiros a comparar os anos de estudos possuídos por um trabalhador e os requeridos pela sua ocupação, e tentaram estimar os impactos dessa diferença nos rendimentos do trabalhador. Para isso, os autores estimaram uma equação minceriana, distinguindo no modelo de determinação de salários os anos de estudos possuídos e requeridos, e como resultado encontram que a educação requerida possui um retorno salarial duas vezes maior que a educação possuída pelo indivíduo. Desde então, parte da literatura tem utilizado estratégias semelhantes para medir so impactos salariais da sobreeducação. Muitos desses estudos apontam que indivíduos *overeducated* possuem um retorno salarial menor que os trabalhadores cujos empregos correspondem ao nível de instrução (Rumberger, 1981; Sicherman, 1991; Groot, 1996).

No Brasil, há ainda um número reduzido de pesquisas sobre o *overeducation*. Santos (2002) procurou verificar a incidência e o prêmio para sobreeducação nos anos de 1992, 1995, 1997 e 1999, a partir dos dados da Pesquisa Nacional por Amostra de Domicílios (PNAD) e encontram uma penalização de 21,25% para os trabalhadores *overeducated*. Já Diaz e Machado (2008) utilizando dados do Censo 2000, encontram uma maior incidência do *overeducation* na região Sul, com um retorno salarial de 12,21%.

Recentemente, Annegues, Oliveira, Figueiredo, e Porto (2018), também utilizando a base de dados de egressos da Universidade Federal da Paraíba (UFPB) cruzada com dados sobre mercado de trabalho da Relação Anual de Informações Sociais (RAIS) investigou quais fatores afetam a probabilidade de um indivíduo estar em uma ocupação com nível de instrução exigido abaixo da sua formação superior, em especial o efeito da área de formação dos egressos. As áreas de humanidades, artes e sociais aplicadas apresentam maior probabilidade dos indivíduos estarem sob overeducation, bem como uma menor chance de deixar essa condição durante alguns anos após a conclusão do curso. Oliveira, Mariano, e Araújo (2019), com dados de indivíduos do Ceará, mostraram que a expansão do ensino superior verificada nos últimos anos aumentou a probabilidade de um egresso se encontrar em situação de *overeducation*.

3. Estratégia Empírica

3.1 Modelo Empírico

O modelo comumente estimado pela literatura consiste em uma versão modificada da equação de salários minceriana, com especificações inspiradas no trabalho de Verdugo e Verdugo (1989):

$$\ln w_i = \beta_0 + \beta_1 E_i + \beta_2 exp_i + \beta_3 exp_i^2 + \beta_4 OV_i + \varepsilon_i, \quad (1)$$

onde o *overeducation* é medido por uma *dummy* com valor 1 se o trabalhador i está em uma ocupação com escolaridade requerida inferior a que ele possui. Os trabalhos que utilizam a especificação (1) se baseiam em dados de cross-section para estimar os coeficientes. Entretanto, a possível existência de variáveis omitidas no modelo, como as habilidades inatas, que determinam tanto o salário quanto a condição de *overeducation*, pode comprometer a validade dessas estimativas. Uma forma de contornar esse problema é o controle da heterogeneidade não observada com a aplicação de técnicas de estimação utilizando dados em painel. O modelo de efeitos fixos consiste em introduzir uma *proxy* para as habilidades individuais e demais fatores fixos no tempo.

Já o controle de não-observáveis variantes no tempo requer o emprego de outras técnicas de identificação, como a abordagem de variáveis instrumentais. Encontrar um bom instrumento, o qual deve ser correlacionado com a variável explicativa endógena e não correlacionado com o termo de erro na equação, nem sempre é uma tarefa trivial, tendo em conta principalmente as limitações impostas pela disponibilidade de dados. Assim, com o objetivo de tratar a presença de fatores fixos e variantes no tempo, o modelo que estimamos para o retorno salarial do *overeducation* inclui efeitos fixos do empregado, da firma, e interações destes com os efeitos de tempo. A especificação (1) assume a forma abaixo:

$$\ln w_{ijt} = \beta_0 + \beta_1 E_{it} + \beta_2 exp_{it} + \beta_3 exp_{it}^2 + \beta_4 OV_{it} + \alpha_i + \delta_j + \alpha_{it} + \delta_{jt} + janela_t + \varepsilon_{ijt} \quad (2)$$

onde o *overeducation* é representado pela *dummy* OV_{it}, que assume valor igual a 1 para os trabalhadores que estão *overeducated* em um determinado ano t; $\ln w_{ijt}$ é o logaritmo do salário do indivíduo i que trabalha na empresa j no ano t; E_{it} os anos de estudo adquiridos; e exp_{it} é a experiência.

Diferentemente das abordagens de painel existentes para o efeito do *overeducation* sobre salário, aqui introduzimos um efeito fixo do indivíduo e um efeito fixo relacionado à firma, representados na equação (2) pelos termos α_i e δ_j, respectivamente. Além de determinar o salário do empregado, características da empresa podem determinar a contratação do indivíduo superqualificado para a vaga de trabalho. Segundo Santos (2002), a existência de *overeducation* no Brasil sinaliza a carência de mão-de-obra qualificada, de maneira que as empresas, na busca de trabalhadores produtivos, vêem na escolaridade mais elevada desses trabalhadores uma sinalização de maior produtividade, contratando-os para os postos.

As interações dos efeitos dos trabalhadores e das firmas com o tempo surgem como uma aproximação das características não observadas variante no tempo. Esse procedimento é inspirado na estratégia de Baltagi et al. (2014). Os autores, analisando determinantes dos acordos comerciais, trabalham com uma estrutura de painel com efeitos em três dimensões: um efeito fixo relacionado aos pares de países com relações comerciais e interações de cada país com a dimensão de tempo. No modelo aqui estimado, as interações são representadas pelos termos α_{it} e δ_{jt}.

O termo $janela_t$ representa um conjunto de *dummies* para cada uma das seis janelas de seis anos na qual dividimos a amostra. A inclusão das janelas no modelo permite comparar as diferenças salariais entre os trabalhadores com excesso de qualificação e os corretamente alocados dentro de uma mesma janela de anos.

3.2 Estimação

O modelo de dados em painel a ser estimado possui mais de duas dimensões. Além do efeito fixo do indivíduo, tem-se os efeitos fixos da firma e os efeitos de interações indivíduo-ano e firma-ano. Isto demanda, portanto, um método de estimação para paineis com mais de duas dimensões. Carneiro et al. (2009) propuseram um método, empregado na estimação de um modelo de regressão com mais de 26 variáveis, um conjunto de dados de 26 milhões de observações e dois efeitos fixos, trabalhador e firma. A sua implementação, entretanto, se mostrou altamente custosa computacionalmente. Guimarães e Portugal (2009), então, desenvolveram um algoritmo que permite estimar um modelo com mais de um efeito fixo de forma mais simples.

Considere agora o seguinte modelo de regressão linear na sua forma matricial com a introdução de três efeitos fixos:

$$Y = Z\beta + D_1\lambda + D_2\theta + D_3\delta + \varepsilon, \tag{3}$$

em que Z é uma matriz de variáveis explicativas e D_1, D_2 e D_3 são matrizes com alta dimensão que comportam as dummies dos efeitos fixos. Assim, têm-se as equações matriciais

$$\begin{bmatrix} \beta = \left(Z'Z\right)^{-1}Z'\left(Y - D_1\lambda - D_2\theta - D_3\delta\right) \\ \lambda = \left(D_1'D_1\right)^{-1}D_1'\left(Y - Z\beta - D_2\theta - D_3\delta\right) \\ \theta = \left(D_2'D_2\right)^{-1}D_2'\left(Y - Z\beta - D_1\lambda - D_3\delta\right) \\ \delta = \left(D_3'D_3\right)^{-1}D_3'\left(Y - Z\beta - D_1\lambda - D_2\theta\right) \end{bmatrix},$$

as quais sugerem uma solução iterativa na qual a estimação de cada parâmetro do modelo depende dos demais. O ponto chave do procedimento de Guimarães e Portugal (2009) é que a dimensão das matrizes de variáveis *dummy* não mais representa

uma preocupação. Os termos $(D'D)^{-1}$ são matrizes genéricas que consistem em uma transformação dos dados com as médias intragrupos. Além disso, $D_1\lambda$, $D_2\theta$ e $D_3\delta$ entram nas equações como vetores coluna contendo todos os elementos de λ, θ e δ. O estimador usual de MQO considerando os efeitos fixos é fruto de uma regressão linear simples da variável dependente Y transformada (livre dos efeitos fixos) sobre o conjunto de variáveis exógenas Z. Aqui, em vez de transformar Y, ela é mantida como variável dependente em sua integridade e $D_1\lambda$, $D_2\theta$ e $D_3\delta$ entram na regressão como covariadas adicionais. Os coeficientes de $D_1\lambda$, $D_2\theta$ e $D_3\delta$ serão iguais a um e cada vetor por sua vez será formado pelos coeficientes estimados das variáveis *dummies* se estas fossem incluídas no modelo.

3.3 Regressão Quantílica

As estimativas do procedimento de Guimarães e Portugal (2009) fornecem o efeito médio do *overeducation*. No entanto, é possível que haja uma variabilidade de efeitos dentro da distribuição de salários e a estimação na média pode subestimar (superestimar) esses impactos.

Além disso, os valores estimados para cada quantil podem fornecer uma ideia do papel das habilidades individuais e do *overeducation* na determinação dos salários. A hipótese, pontuada por McGuinness (2006), assume que a posição relativa do indivíduo na distribuição dos rendimentos define seu grau de habilidade. Considerando que a amostra é composta por indivíduos com níveis similares de escolaridade, é razoável supor que indivíduos mais habilidosos estariam localizados nos quantis de salário mais altos. A regressão quantílica permite observar as diferenças salariais entre os *overeducated* e seus pares corretamente alocados dentro de um mesmo nível de habilidade; se, por exemplo, o *overeducation* penaliza em maior grau trabalhadores menos habilidosos, há um indício em favor da tese de que as diferenças de rendimento em razão do *overeducation* estão mais ligadas às diferenças de habilidades não observadas. Caso o *overeducation* impacte de forma semelhante trabalhadores com diferentes níveis de habilidade, põe-se em dúvida a tese da influência das habilidades.

Dito isso, também estimou-se o modelo descrito em (2) por regressões quantílicas. Outras vantagens da utilização de regressões quantílicas são: a robustez a *outliers*; o fornecimento de estimadores mais eficientes em comparação com os obtidos via OLS; e não necessidade da hipótese de distribuição normal.

O método de estimação que empregamos se trata de uma adaptação da abordagem de painel quantílico de Canay (2011). Originalmente, o método do autor consiste em uma transformação dos dados que consegue eliminar os efeitos fixos, considerando que estes afetam igualmente todos os quantis. Para uma compreensão mais detalhada da técnica, considere inicialmente o seguinte modelo de regressão em painel com efeito fixo:

$$y_{it} = x'_{it}\beta + \alpha_i + \varepsilon_{it}, \qquad \mathbb{E}\left(\varepsilon_{it} \,|\, x_{it}, \alpha_i\right) = 0, \tag{4}$$

onde $\left(y_{it}, x_{it}\right) \in \mathbb{R} \times \mathbb{R}^k$ são variáveis observáveis; $\theta\left(U_{it}\right) = \beta$ e $\left(U_{it}, \alpha_i\right) \in \mathbb{R} \times \mathbb{R}$ são fatores não observados; $U_{it}|x_{it}, \alpha_i \approx U[0,1]$. Assume-se que a função $\tau \to x'\theta(\tau)$ é estritamente crescente em $\tau \in (0,1)$ e que $\theta(\tau)$ representa o parâmetro de interesse.

A principal restrição é que as heterogeneidades individuais, representadas pelos efeitos fixos α_i, afetam a variável resposta dos indivíduos da mesma forma em todos os quantis.

Sendo $\mathbb{E}_T(\cdot) \equiv T^{-1}\sum_{t=1}^{T}(\cdot)$ e $\mathbb{E}_{nT}(\cdot) \equiv (nT)^{-1}\sum_{t=1}^{T}\sum_{i=1}^{n}(\cdot)$, Canay (2011) sugere um procedimento em dois estágios para estimação da equação (6).

Passo 1: Seja $\hat{\theta}_\mu$ um estimador $\sqrt{nT}$ consistente de θ_μ. Os estimadores dos efeitos fixos têm a forma

$$\hat{\alpha}_i \equiv \mathbb{E}_T\left[y_{it} - x_{it}'\hat{\theta}_\mu\right]. \tag{5}$$

Passo 2: Fazendo a seguinte transformação na variável dependente $\hat{y}_{it} = y_{it} - \hat{\alpha}_i$, define-se o estimador de regressão quantílica $\hat{\theta}(\tau)$ como sendo

$$\hat{\theta}(\tau) = \arg\min_{\theta\in(\cdot)} \mathbb{E}_{nT}\left[\rho_r\left(\hat{y}_{it} - x_{it}'\theta_\mu\right)\right]. \tag{6}$$

No primeiro passo, procede-se a uma estimação OLS com as variáveis explicada e explicativas originais. Os resíduos da regressão contêm todos os fatores não observáveis que afetam y_{it} para cada indivíduo, de modo que a sua média no tempo, dada por $\mathbb{E}_T\left[y_{it} - x_{it}'\hat{\theta}_\mu\right]$, pode ser utilizada como uma *proxy* para os efeitos fixos individuais. Por fim, o segundo estágio consiste na aplicação do estimador de regressões quantílicas substituindo a variável dependente pelo seu valor deduzido dos efeitos fixos individuais.

Aqui adotamos um procedimento semelhante, porém não utilizamos a média dos resíduos da regressão OLS, mas sim os próprios efeitos fixos, cujos valores são fornecidos pelo método de Guimarães e Portugal (2009). O algoritmo desenvolvido pelos autores consegue salvar os efeitos fixos como variáveis, de todas as dimensões consideradas (empregado, firma e interações com o tempo). Em resumo, a) estimamos a equação (2) por OLS para mais de dois efeitos fixos, b) salvamos os efeitos fixos, c) construímos a variável salário livre dos efeitos fixos, e por fim d) estimamos a variável dependente transformada contra as demais variáveis explicativas através da regressão quantílica.

4. Dados

O banco de dados é resultado do cruzamento de informações acadêmicas dos egressos da Universidade Federal da Paraíba (UFPB), Campus I, localizada em João Pessoa, na Paraíba, fornecidas pela Superintendência de Tecnologia da Informação (STI) da UFPB e informações acerca da sua ocupação presentes na Relação Anual de Informações Sociais (RAIS). A variável de ligação entre as duas bases é o CPF do ex-aluno. Foram considerados os alunos graduados na UFPB a partir de 2003, acompanhados ao longo do tempo por pelo menos cinco anos. Assim temos as seguintes janelas de tempo: 2003–2008, 2004–2009, 2005–2010, 2006–2011, 2007–2012 e 2008–2013. Após a junção dos dados da UFPB com os dados da RAIS e a seleção dos egressos presentes em ambas as bases, tem-se um total de 4.598 observações.

A STI possui dados que abrangem a vida acadêmica de todos os alunos durante a graduação, como o semestre no qual ingressou e no qual finalizou o curso e a área de formação do concluinte (Ciências Jurídicas, Sociais Aplicadas, Saúde, Engenharia). Essa

informação é interessante, pois nos permite estimar o retorno salarial do *overeducation* em cada campo de atuação, tendo em vista as evidências de que o fenômeno tende a ser mais comum em determinados campos de estudo (ver seção 2).

Os dados ainda contêm informações coletadas na aplicação de um questionário socioeconômico no momento do vestibular, feita pela Comissão Permanente de Vestibular (COPERVE), responsável pela realização do processo seletivo para a UFPB até 2013. Os dados dizem respeito a características socioeconômicas dos alunos, como sexo, raça, grau de instrução dos pais (*background* familiar), e informações sobre sua vida escolar antes de entrar na faculdade (nota no vestibular, rede de ensino na qual cursou o ensino médio e etc.). Na RAIS constam as características individuais dos trabalhadores (raça, sexo, grau de instrução, idade, tipo de admissão, salário anual) e informações sobre as ocupações e sobre as empresas, como seu porte, classificação de atividade e natureza jurídica.

A construção do indicador de *overeducation* depende de como se mede a escolaridade requerida por uma determinada ocupação. Existem três formas principais nas quais a literatura se baseia: i) *Job Analysis*, ii) *Realized Matches*, e iii) *Self-Assessment*. A primeira consiste em utilizar uma classificação ocupacional, na qual analistas de trabalho definem os graus de escolaridade necessários para as ocupações. No *Realized Matches*, calcula-se a escolaridade média dos trabalhadores inseridos em cada ocupação e a que possuem escolaridade superior à média mais o desvio-padrão de sua ocupação são classificados como *overeducated*. Já no *Sef-Assessment* o próprio trabalhador reporta o nível de instrução requerido pelo seu trabalho ou ele responde diretamente se o *match* entre sua ocupação e seu nível de instrução é adequado.

Dada a disponibilidade dos dados, aqui empregamos a abordagem do *Job Analysis* para definir se o egresso é ou não *overeducated*. Uma das variáveis presente na RAIS é a ocupação do egresso, segundo o sistema da Classificação Brasileira de Ocupações (CBO) de 2002. De acordo com o Ministério do Trabalho e Emprego (MTE) a ocupação é a agregação de empregos ou situações de trabalho similares quanto às atividades realizadas. Sendo assim, CBO 2002 agrega os empregos por habilidades cognitivas comuns exigidas no exercício de um campo de trabalho.[2]

O nível mais agregado da CBO 2002 são os grandes grupos formado por dez conjuntos, agregados por nível de competência e similaridade nas atividades executadas, descritos na Tabela 1. A CBO 2002 toma como base, com algumas adaptações, a metodologia da classificação e agregação internacional de informações ocupacionais de 1988 a *International Standard Classification of Occupations* (ISCO 88) que utiliza a escolaridade como critério para determinar o nível de competência. Os graduados cuja ocupação na CBO tenha nível de escolaridade exigido menor que o ensino superior são considerados sobreeducados e, assim, a *dummy* de *overeducation* será igual a um.

As variáveis que utilizamos no modelo (2) têm como fonte a RAIS. O salário corresponde ao rendimento médio anual do trabalhador, deflacionado pelo Índice Nacional de Preços ao consumidor. A experiência corresponde ao tempo de emprego

[2]O MTE define o sistema de classificação da CBO 2002 como um documento normalizador do reconhecimento para fins classificatórios, sem função de regulamentação profissional, da nomeação e da codificação dos títulos e conteúdos das ocupações do mercado de trabalho brasileiro para fins estatísticos de registros administrativos, censos populacionais e outras pesquisas domiciliares.

Tabela 1. Grande Grupo CBO 2002.

Código	Título
0	Membros das Forças Armadas, Policiais e Bombeiros Militares
1	Membros Superiores do Poder Público, Dirigentes de Organizações de Interesse Público e de Empresas, Gerentes
2	Profissionais das Ciências e das Artes
3	Técnicos de Nível Médio
4	Trabalhadores de Serviços Administrativos
5	Trabalhadores dos Serviços, Vendedores do Comércio em Lojas e Mercados
6	Trabalhadores Agropecuários, Florestais e da Pesca
7	Trabalhadores da Produção de Bens e Serviços Industriais
8	Trabalhadores da Produção de Bens e Serviços Industriais
9	Trabalhadores em Serviços de Reparação e Manutenção

Fonte: Elaboração própria a partir da Classificação Brasileira de Ocupações.

do trabalhador em meses. Embora tenhamos selecionados indivíduos graduados, introduzimos aqui a variável anos de estudo, pois após a conclusão da graduação alguns indivíduos aumentam seu grau de instrução, fazendo especializações, mestrado e/ou doutorado.

A Tabela 2 mostra um perfil sócioeconômico dos trabalhadores corretamente alocados (*matched*) e os trabalhadores *overeducated*. São apresentadas médias das variáveis utilizadas nas estimações, bem como a composição das duas amostras no tocante ao gênero, à raça, à idade e características das firmas.

Os trabalhadores *overeducated* apresentam uma média de salário inferior aos *matched*. Embora seja uma mera comparação de médias, mostra um indício da penalização salarial gerada pelo excesso de qualificação. Ambos os grupos apresentam médias de idade e de duração do curso universitário bastante próximas. Os *overeducated* possuem mais tempo de emprego em média e a maioria é composta por indivíduos do sexo feminino, não brancos e oriundos de escolas públicas. Esses grupos, em especial os não brancos de escolas públicas, apresentam historicamente piores condições de renda e educação, de maneira que esses fatores tendem a contribuir para que obtenham menores ganhos salariais e ao mesmo tempo para sua situação de vulnerabilidade social, os conduzindo a ocupações com qualificação requerida inferior.

A Tabela 3 mostra a média das variáveis incluídas no modelo empírico que estimamos para cada janela de tempo. Acompanhando a evolução das médias salariais, percebe-se uma elevação, embora a diferença existente entre os corretamente alocados e os *overeducated* tenha se mantido. A desigualdade salarial aumentou de uma janela a outra e os egressos com excesso de qualificação tiveram mais tempo de experiência entre as janelas e em comparação com o grupo *matched*. Destaque-se que muitos egressos estão presentes em mais de uma janela, pela interseção entre os anos.

Tabela 2. Perfil Sócioeconômico – Corretamente Alocados (*Matched*) e *Overeducated*.

		Matched	*Overeducated*
		Média	
Salário		1.211,38	953,32
Idade		28,08	27,4
Anos de Estudo		16,03	16
Tempo de Emprego		33,8	35,8
Variáveis Sócioeconômicas		%	
Sexo	Feminino	48,3	50,2
	Masculino	51,7	49,8
Cor	Brancos	52,6	45,8
	Não Brancos	47,4	54,2
Rede Escolar Nível Médio	Particular	51,4	42,2
	Pública	48,6	57,8
Renda Familiar	Menos de R$ 622,00	31,8	34,5
	De R$ 622,00 a R$ 1.865,99	39,0	39,6
	R$ 1.866,00 ou mais	29,2	25,8
Escolaridade do Pai	Analfabeto	26,88	34,2
	Fundamental	13,28	17,1
	Médio	31,51	28,3
	Superior ou mais	28,33	20,3
CBO 2002 Ano de Formação	Desempregado	69,9	64,4
	CBO1	2,9	0,8
	CBO2	4,5	0,6
	CBO3	3,9	5,4
	CBO4	10,0	14,9
	CBO5	5,1	7,7
	CBO7	1,2	2,0
	CBO8	1,0	1,8
	CBO9	1,5	2,5
Emprego Temporário	Não	99,7	99,5
	Sim	0,3	0,5
CNAE 2.0	Agropecuária e Pesca	0,1	0,1
	Indústria	8,4	12,5
	Construção Civil	2,2	2,4
	Comércio	11,8	14,9
	Serviços	77,4	70,1
Porte da Empresa	Micro	17,8	21,4
	Pequena	15,2	16,2
	Média	14,4	16,1
	Grande	52,7	46,3
Primeiro Emprego	Não	81,0	85,5
	Sim	19,0	14,4
Nascido em João Pessoa	Não	50,9	46,8
	Sim	49,1	53,2

Fonte: Elaboração própria a partir dos dados da STI/UFPB e da RAIS.

Tabela 3. Média das Variáveis por Janela.

	Janelas					
	$t = 1$	$t = 2$	$t = 3$	$t = 4$	$t = 5$	$t = 6$
Matched						
Salário	858,9	918,24	1.014,7	1.114	1.176,11	1.270,91
Anos de Estudo	16	16,5	16,08	17,01	16,02	16,04
Tempo de Emprego	39,4	34,09	30,46	29,66	29,71	29,17
Overeducated						
Salário	703,52	745,6	806,9	868,3	954,16	1057,35
Anos de Estudo	16	17,001	16,04	16	16,06	16
Tempo de Emprego	32,3	32,75	33,72	35,20	36,51	37,1

Fonte: Elaboração própria a partir dos dados da STI/UFPB e da RAIS.

5. Resultados

Esta seção apresenta os impactos do *overeducation* sobre os ganhos salariais dos graduados na UFPB, encontrados com os procedimentos descritos anteriormente. Na análise descritiva dos dados feita na seção anterior, os trabalhadores *overeducated* apresentaram um salário médio menor que seus pares corretamente alocados. Aqui adicionamos técnicas para o controle do viés de seleção afim de fornecer maior robustez aos indícios apontados pelas diferenças de média salarial.

A Tabela 4 traz os valores dos coeficientes estimados via mínimos quadrados considerando quatro especificações. Na primeira, estimamos a equação minceriana modificada com um *pooled* OLS, sem considerar os efeitos fixos do empregado, da firma e das interações de ambos com o tempo. De um modelo ao outro cada um desses elementos foram incluídos até chegar na especificação mais completa do modelo 4. A variável dependente é o logarítimo do salário médio recebido pelo empregado e *overeducation* é a variável de interesse, com valor 1 para o indivíduo *overeducated* em determinado ano dentro da janela.

Considerando todas as especificações o coeficiente do *overeducation* foi negativo e significante. Ou seja, os trabalhadores de nível superior em ocupações que exigem menor escolaridade auferem menor salário quando comparados aos trabalhadores com a mesma qualificação em postos de trabalho coerentes com sua formação. Com a introdução dos efeitos fixos, nota-se uma redução na magnitude dos coeficientes, indicando que um procedimento de identificação que não considera a influência de fatores não-observados, como no caso do *pooled* OLS tende a viesar o valor das estimativas.

Quando os efeitos das interações com o tempo são considerados, o viés gerado pelo OLS simples fica ainda mais evidente. Nessa especificação, indivíduos *overeducated* têm uma redução de 0,1183 unidades monetárias no seu salário médio quando comparados aos trabalhadores corretamente alocados. Os resultados encontrados são consonantes com a maior parte da literatura, cujas pesquisas mostram uma redução salarial associada ao *overeducation*. Analisando os resultados de Bauer (2002) e Chevalier (2003), vemos algumas diferenças, embora ambos também lancem mão de métodos para tratar a heterogeneidade não observada. Chevalier (2003) também mostra um

Tabela 4. Retorno Salarial do *overeducation* – Estimação por OLS.

Variável Dependente: Log do salário médio				
	Modelos			
Variáveis	(1)	(2)	(3)	(4)
Overeducation	−0,1831***	−0,1261***	−0,1435***	−0,1183***
	(0,0201)	(0,0209)	(0,0228)	(0,0225)
Anos de Estudo	0,2977***	0,1027***	0,0217	0,0158
	(0,0412)	(0,0368)	(0,0328)	(0,0458)
Experiência	0,0055***	0,0007*	0,0036***	0,001**
	(0,0003)	(0,0004)	(0,0003)	(0,0005)
Experiência^2	−0,0001**	−0,00004	−0,00006***	−0,00001***
	(0,0003)	(0,00001)	(0,00001)	(0,00002)
Janelas (*Dummies*)	Sim	Sim	Sim	Sim
Empregado (FE)	Não	Sim	Sim	Sim
Firma (FE)	Não	Não	Sim	Sim
Interações	Não	Não	Não	Sim
N.obs.	(4.598)	(4.598)	(4.598)	(4.598)
R^2	0,2304	0,8313	0,9279	0,9432

Nota: Elaboração própria a partir das estimações.
Fonte: Erro-padrão entre parênteses. $^{*}p < 0{,}10$; $^{**}p < 0{,}05$; $^{***}p < 0{,}01$.

efeito negativo do excesso de qualificação, porém com uma magnitude maior. Já Bauer (2002), que utilizou um painel com efeitos fixos do indivíduo, não encontrou diferença estatisticamente significante entre os salários dos *overeducated* e seus pares.

A experiência gera ganhos de salários até um ponto a partir do qual os rendimentos do trabalhador começam a diminuir. Já os anos de estudo não apresentaram efeito estatisticamente significante na especificação mais completa. Muitos egressos analisados permaneceram apenas com o curso de graduação, embora alguns tenham aumentado seus anos de estudo com cursos de pós-graduação.

Na Tabela 5 tem-se as estimações por área de formação dos egressos. Os cursos de graduação da UFPB são agrupados em centros de acadêmicos de acordo com as similaridades das áreas de estudo dos cursos. O Centro de Ciências Médicas e da Saúde, por exemplo, reuném os cursos de medicina, biomedicina, nutrição e etc., enquanto que o Centro de Ciências Sociais Aplicadas (CCSA) contém os cursos ligados a negócios, como Administração, Ciências Contábeis e Economia. Sendo assim, tal qual em Annegues et al. (2018), consideramos os centros acadêmicos como as áreas de formação dos egressos. Na área de Humanas consideramos os egressos dos cursos do Centro de Ciências Humanas Letras e Artes (CCHLA), do Centro de Educação (CE) e do Centro de Ciências Jurídicas. Nas exatas, os egressos do Centro de Ciências Exatas e da Natureza (CCEN) e do Centro de Tecnologia (CT), o qual reúne os cursos de Engenharia. Na área da Saúde, os egressos dos Centros de Ciências Médicas e da Saúde (CCM e CCS).

Tabela 5. Retorno Salarial do *overeducation* por área de formação.

Variável Dependente: Log do salário médio				
	Áreas de Estudo			
Variáveis	Humanas	Exatas	Saúde	Sociais Aplicadas
Overeducation	−0,0203	−0,2010***	−0,1487**	−0,0177
	(0,0430)	(0,0463)	(0,068)	(0,0472)
Anos de Estudo	0,0256**	0,0361	0,1113	0,1809*
	(0,011)	(0,0577)	(0,1262)	(0,0911)
Experiência	0,004**	0,0025	−0,00024	0,0064***
	(0,0011)	(0,0004)	(0,002)	(0,0013)
Experiência^2	−0,0001***	−0,00004	−0,00001	−0,00002***
	(0,00005)	(0,00001)	(0,00001)	(0,00004)
Janelas (*Dummies*)	Sim	Sim	Sim	Sim
Empregado (FE)	Sim	Sim	Sim	Sim
Firma (FE)	Sim	Sim	Sim	Sim
Interações	Sim	Sim	Sim	Sim
N.obs.	761	605	714	647
R^2	0,9415	0,9295	0,9522	0,9677

Nota: Elaboração própria a partir das estimações.
Fonte: Erro-padrão entre parênteses. * $p < 0{,}10$; ** $p < 0{,}05$; *** $p < 0{,}01$.

Apenas nas áreas de Exatas e Saúde foram identificadas diferenças significativas de salário em razão do *overeducation*. O alto retorno associado a estas profissões e a exigência de certificações para o seu exercício, as quais definem bem as ocupações condizentes com a área de formação, podem explicar este resultado.

Além dos resultados por área de formação, também estimamos os resultados por gênero, raça, rede de ensino no qual o egresso cursou o ensino médio e escolaridade dos pais (Tabela 6). Em todas as categorias houve redução estatisticamente significante de salário. As mulheres apresentaram maior magnitude de coeficiente, sendo mais penalizadas em razão da condição de *overeducated*.

Com relação à raça, brancos e não brancos apresentaram praticamente os mesmos coeficientes. No tocante ao *Background Familiar*, aqui medido pela escolaridade do pai, os *overeducated* filhos de pais com ensino superior tiveram uma redução no salário de 0,2075, resultado próximo dos filhos de pais com ensino fundamental. Os *overeducated* que estudaram em escolas particulares tiveram maior coeficiente relativamente aos oriundos de escolas públicas.

Mesmo com os controles pelos efeitos fixos do indivíduo e da firma e das interações desses efeitos com o tempo, queremos testar o papel das habilidades individuais na determinação dos salários. Para isso, seguindo a estratégia sugerida por McGuinness (2006), estimamos o impacto do *overeducation* por quantis. Supondo que os quantis de salário refletem os níveis de habilidades, ao comparar a diferença de salário entre *overeducated* e corretamente alocados dentro de cada quantil, comparamos indivíduos com

Tabela 6. Resultado OLS por gênero, raça, rede de ensino e escolaridade dos pais.

Variáveis	*Overeducation*	Erro-Padrão	R^2
Homens	−0,0899***	0,0323	0,9516
Mulheres	−0,1297***	0,0320	0,9330
Brancos	−0,1108***	0,0305	0,9536
Não Brancos	−0,1140***	0,0331	0,9348
Escolaridade do Pai			
Analfabeto	−0,0250	0,0382	0,9456
Ensino fundamental	−0,1996***	0,0542	0,9640
Ensino médio	−0,1200***	0,0453	0,8852
Ensino superior ou mais	−0,2075***	0,0448	0,9292
Rede onde cursou o ensino médio			
Pública	−0,1212***	0,0298	0,9366
Privada	−0,1334***	0,0348	0,9509

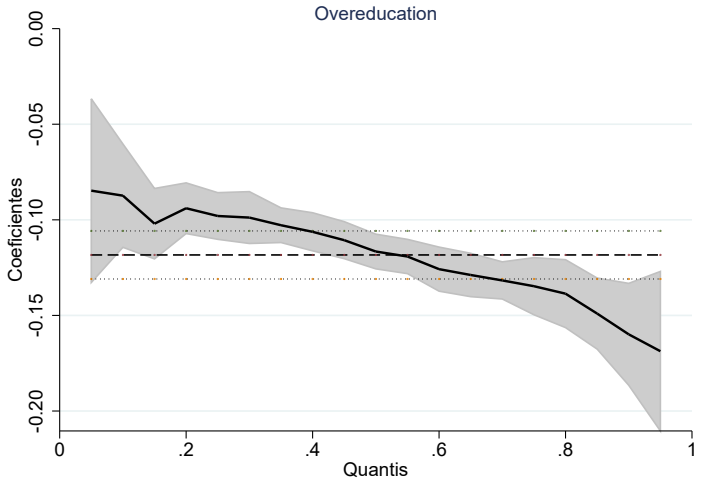
Nota: Elaboração própria a partir das estimações.
Fonte: Erro-padrão entre parênteses. * $p < 0{,}10$; ** $p < 0{,}05$; *** $p < 0{,}01$.

mesma habilidade. Além disso, a estimação na média pode mascarar a variabilidade de efeitos do *overeducation* entre os diversos pontos da distribuição salarial.

O gráfico da Figura 1 mostra os coeficientes estimados ao longo dos quantis de salário. São plotadas no gráfico as estimativas da dummy de *overeducation* para cada quantil entre 0,05 e 0,95, bem como o intervalo de confiança de 95%, representado pela área cinza em volta da curva. Já a linha horizontal representa o efeito na média condicional dos salários. Tal qual as estimativas por mínimos quadrados, o *overeducation* apresentou efeito negativo em todos os quantis. Analisando a magnitude dos efeitos, vemos que os indivíduos localizados nos menores quantis têm a menor diferença de salário em relação aos corretamente alocados.

Ao longo da distribuição o efeito se torna cada vez mais negativo, de maneira que os indivíduos nos maiores quantis de salário, que seriam os mais habilidosos de acordo com nossa hipótese levantada acima, são os que apresentaram maior redução de salários em razão do excesso de educação. Ou seja, existem indícios que vão contra a tese de que as diferenças de rendimento entre corretamente alocados e *overeducated* estão mais ligadas às diferenças de habilidades não observadas. O artigo de McGuinness (2006), por outro lado, mostra evidências em favor dessa hipótese, uma vez que os coeficientes se mostraram mais negativos para aqueles localizados nos quantis inferiores.

Mesmo estando em ocupações que exigem menos escolaridade, a maior habilidade dos egressos nos quantis superiores poderia conferir um ganho salarial extra em relação aos demais trabalhadores da função e compensar a diferença de rendimento médio relativamente aos indivíduos de nível superior em postos de trabalhos condizentes com a escolaridade. No entanto, os resultados por quantis sugerem que essa compensação não ocorre.



Fonte: Elaboração própria a partir das estimações.

Figura 1. Retorno Salarial do *overeducation* – Regressão Quantílica.

6. Considerações Finais

O presente artigo investigou como o *overeducation*, que é o excesso de qualificação em relação ao que é requerido pelo emprego, afeta o salário recebido. Dada a recente expansão da oferta de trabalhadores com nível superior ocorrida no Brasil, analisamos o retorno salarial do *overeducation* para indivíduos graduados na UFPB. Identificamos estes egressos na Relação Anual de Informações Sociais (RAIS), acompanhando-os entre os anos de 2003 e 2013.

O ponto central na identificação do efeito do *overeducation* sobre o salário é o possível viés de seleção dos indivíduos *overeducated*. Fatores não observados, em especial as habilidades inatas, podem determinar tanto o salário do egresso quando a situação de estar em uma ocupação que não requer o seu grau de instrução. Nesse sentido, a estratégia de identificação que adotamos consiste em uma estimação com efeitos fixos do indivíduo e da firma na qual trabalha e interações destes fatores com o tempo. Essas interações surgem como *proxies* das características não observadas variantes no tempo, uma vez que métodos mais sofisticados, como o uso de variáveis instrumentais, nem sempre são factíveis em razão da disponibilidade de dados. Para testar a hipótese de que a desigualdade de salário entre *overeducated* e corretamente alocados é produto das diferenças de habilidade, a equação de salários foi estimada via regressão quantílica. Supondo que a posição relativa dos indivíduos na distribuição de salários identifique o seu nível de habilidade, se o *overeducation* penaliza mais os egressos de quantis inferiores, há indícios de que a habilidade exerce um papel importante na determinação dos salários vis-à-vis a condição de *overeducation*.

Em suma, os resultados mostraram que egressos *overeducated* têm uma redução salarial quando comparados com seus pares cuja ocupação corresponde à sua escolaridade. Tal redução se mostrou mais forte para indivíduos formados nas áreas de ciências exatas e saúde, e do sexo feminino. Já os resultados da estimação por quantis mostrou que o *overeducation* afeta negativamente mais os salários dos indivíduos localizados no topo da distribuição de salários, ou seja, aqueles com maior nível de habilidade.

Desse modo, há indícios de que a habilidade parece não ser determinante para o menor salário auferido pelos *overeducated*.

As habilidades inatas destes trabalhadores parecem não ser suficientes a ponto de lhes fornecer um prêmio salarial próximo ao que teriam caso estivessem em uma ocupação que exige o ensino superior. As evidências que encontramos seguem a mesma direção de boa parte desta literatura e mostram que o *overeducation* consiste em um sinal de ineficiência dos gastos em educação, uma vez que estes nem sempre se traduzem em ganhos de renda e maior mobilidade social.

Referências bibliográficas

Annegues, A. C., Oliveira, C., Figueiredo, E., & Porto, S., Jr. (2018, 4–5 de julho). Overeducation e área de formação: Evidências para os egressos da UFPB. *In XXIII Encontro Regional de Economia*, Fortaleza, CE. https://www.anpec.org.br/nordeste/2018/submissao/arquivos_identificados/057-30545e4aac19d96be6b75873119c721d.pdf

Baltagi, B. H., Egger, P. H., & Pfaffermayr, M. (2014, janeiro). *Panel data gravity models of international trade* (CESifo Working Paper Nº 4616). Munich, Germany: CESifo. https://www.ifo.de/DocDL/cesifo1_wp4616.pdf

Bauer, T. K. (2002). Educational mismatch and wages: A panel analysis. *Economics of Education Review*, *21*(3), 221–229. http://dx.doi.org/10.1016/S0272-7757(01)00004-8

Becker, G. S. (1962). Investment in human capital: A theoretical analysis. *Journal of Political Economy*, *70*(5, Part 2), 9–49. https://www.jstor.org/stable/1829103

Canay, I. A. (2011). A simple approach to quantile regression for panel data. *The Econometrics Journal*, *14*(3), 368–386. http://dx.doi.org/10.1111/j.1368-423X.2011.00349.x

Carneiro, A., Guimarães, P., & Portugal, P. (2009, maio). *Real wages and the business cycle: Accounting for worker and firm heterogeneity* (IZA Discussion Paper Nº 4174). Bonn, Germany: Forschungsinstitut zur Zukunft der Arbeit GmbH (IZA). http://ftp.iza.org/dp4174.pdf

Chevalier, A. (2003). Measuring over-education. *Economica*, *70*(279), 509–531. http://dx.doi.org/10.1111/1468-0335.t01-1-00296

Cohn, E., & Ng, Y. C. (2000). Incidence and wage effects of overschooling and underschooling in Hong Kong. *Economics of Education Review*, *19*(2), 159–168. http://dx.doi.org/10.1016/S0272-7757(99)00006-0

Diaz, M. D. M., & Machado, L. (2008). Overeducation e undereducation no Brasil: Incidência e retornos. *Estudos Econômicos*, *38*(3), 431–460. http://dx.doi.org/10.1590/S0101-41612008000300001

Dolton, P. J., & Silles, M. A. (2008). The effects of over-education on earnings in the graduate labour market. *Economics of Education Review*, *27*(2), 125–139. http://dx.doi.org/10.1016/j.econedurev.2006.08.008

Dolton, P. J., & Vignoles, A. (2000). The incidence and effects of overeducation in the U.K. graduate labour market. *Economics of Education Review*, *19*(2), 179–198. http://dx.doi.org/10.1016/S0272-7757(97)00036-8

Duncan, G. J., & Hoffman, S. D. (1981). The incidence and wage effects of overeducation. *Economics of Education Review*, *1*(1), 75–86. http://dx.doi.org/10.1016/0272-7757(81)90028-5

Freeman, R. (1976). *The overeducated American*. Academic Press.

Groot, W. (1996). The incidence of, and returns to overeducation in the UK. *Applied Economics*, *28*(10), 1345–1350. http://dx.doi.org/10.1080/000368496327895

Guimarães, P., & Portugal, P. (2009, janeiro). *A simple feasible alternative procedure to estimate models with high-dimensional fixed effects* (IZA Discussion Paper Nº 3935). Bonn, Germany: Forschungsinstitut zur Zukunft der Arbeit GmbH (IZA). http://ftp.iza.org/dp3935.pdf

Kiersztyn, A. (2013). Stuck in a mismatch? The persistence of overeducation during twenty years of the post-communist transition in Poland. *Economics of Education Review*, *32*, 78–91. http://dx.doi.org/10.1016/j.econedurev.2012.09.009

Leuven, E., & Oosterbeek, H. (2011). Overeducation and mismatch in the labor market. *In Handbook of the economics of education* (Vol. 4, pp. 283–326). Amsterdam: Elsevier. http://dx.doi.org/10.1016/B978-0-444-53444-6.00003-1

McGuinness, S. (2006). Overeducation in the labour market. *Journal of Economic Surveys*, *20*(3), 387–418. http://dx.doi.org/10.1111/j.0950-0804.2006.00284.x

Mincer, J. (1974). *Schooling, experience, and earnings* [Human Behavior & Social Institutions, Vol. 2]. New York, NY: National Bureau of Economic Research. https://www.nber.org/books/minc74-1

Morano, C. P. (2014). The determinants of overeducation : Evidence from the Italian labour market Preliminary Draft. *Investigaciones de economía de la educación*, *9*, 681–698. http://repec.economicsofeducation.com/2014valencia/valencia2014.pdf

Oliveira, C., Mariano, F. Z., & Araújo, J. A. (2019, 18–19 de julho). A qualidade e expansão do ensino superior contribui para o overeducation? Evidências para o Ceará. *In XXIV Encontro Regional de Economia*, Fortaleza, CE. https://www.anpec.org.br/nordeste/2019/submissao/arquivos_identificados/054-b43a5baf3e680a1d9e70b2e1ca5157eb.pdf

Reimer, D., Noelke, C., & Kucel, A. (2008). Labor market effects of field of study in comparative perspective: An analysis of 22 European countries. *International Journal of Comparative Sociology*, *49*(4-5), 233–256. http://dx.doi.org/10.1177/0020715208093076

Rumberger, R. W. (1981). The rising incidence of overeducation in the U.S. labor market. *Economics of Education Review*, *1*(3), 293–314. http://dx.doi.org/10.1016/0272-7757(81)90001-7

Santos, A. M. d. (2002). Overeducation no mercado de trabalho brasileiro. *Revista Brasileira de Economia de Empresas*, *2*(2), 1–22. https://portalrevistas.ucb.br/index.php/rbee/article/view/4377

Sattinger, M. (1993). Assignment models of the distribution of earnings. *Journal of Economic Literature*, *31*(2), 831–880. https://www.jstor.org/stable/2728516

Schank, T., Schnabel, C., & Wagner, J. (2010). Higher wages in exporting firms: Self-selection, export effect, or both? First evidence from linked employer-employee data. *Review of World Economics*, *146*(2), 303–322. http://dx.doi.org/10.1007/s10290-010-0049-7

Schultz, T. W. (1961). Investment in human capital. *The American Economic Review*, *51*(1), 1–17. https://www.jstor.org/stable/1818907

Sicherman, N. (1991). "Overeducation" in the labor market. *Journal of Labor Economics*, *9*(2), 101–122. http://dx.doi.org/10.1086/298261

Smith, J. P., & Welch, F. (1978, novembro). *The overeducated American? A review article* (The Rand Paper Series Nº RAND-P-6253; ERIC ED175340). Santa Monica, CA: Rand Corp. https://eric.ed.gov/?id=ED175340

Thurow, L. C. (1975). *Generating inequality: Mechanisms of distribution in the US economy*. Basic Books.

Verdugo, R. R., & Verdugo, N. T. (1989). The impact of surplus schooling on earnings: Some additional findings. *Journal of Human Resources*, *24*(4), 629–643. http://dx.doi.org/10.2307/145998

r b e
REVISTA BRASILEIRA DE ECONOMIA
DOI 10.5935/0034-7140.20200008
ISSN 1806-9134 (online)
FGV
FUNDAÇÃO GETULIO VARGAS

O FIES Contribui Para a Atratividade das Carreiras de Licenciaturas e da Saúde?

Luís Henrique Romani de Campos[*]
Isabel Pessoa de Arruda Raposo[†]
Tayene Trajano de Moura[‡]
Heitor Victor Veiga da Costa[§]

Sumário

1. Introdução 139
2. O Programa FIES..... 141
3. Modelo empírico e dados... 145
4. Resultados..... 148
5. Conclusões..... 151

Palavras-chave
FIES, cursos prioritários, logit com dados empilhados

JEL Codes
I22, I23, C25

Resumo • Abstract

This paper evaluates the Brazilian Student Loan Fund (FIES) regarding the enrollment of students in courses of two priority areas of the Program: health and education. The identification strategy is based on a change in the FIES rule in 2009, which adopted a significant reduction in the financing rate of approximately 50% and led to a homogenization of interest rates applied between the courses in the areas of education and other courses. Pooled logit models estimates demonstrate that such changes led to an increase in the probability of choosing health courses, in the order of 32%, and a reduction of 46% in the chances of choices in education and teaching courses. These findings reveal that the changes in the Program have been effective for priority health courses but have generated a disincentive for those in the area of education.
área de educação.

1. Introdução

Corseuil (2002) afirma que durante as décadas de 1970 e 1980 o debate econômico acerca da concentração de renda no Brasil esteve centrado na carência de mão de obra qualificada, ou em outros termos, na carência de pessoas que possuíssem o ensino superior. Aliado a pouca oferta de vagas no ensino superior o crescimento econômico ampliava cada vez mais a concentração, visto que o sistema de ensino era incapaz de suprir a demanda por profissionais. As universidades públicas, com melhor nível de ensino, possuíam acesso muito restrito, dada a pequena capacidade de oferta, fazendo

[*]Fundação Joaquim Nabuco, Núcleo de Estudos em Estatísticas Sociais (Fundaj/MEC). Avenida Dezessete de Agosto, 2187, Casa Forte, Recife, PE, CEP 52061-540, Brasil. 0000-0002-0801-7857

[†]Fundação Joaquim Nabuco, Núcleo de Estudos em Estatísticas Sociais (Fundaj/MEC). Avenida Dezessete de Agosto, 2187, Casa Forte, Recife, PE, CEP 52061-540, Brasil. 0000-0001-7304-546X

[‡]Universidade Federal de Minas Gerais, Centro de Desenvolvimento e Planejamento Regional (UFMG/Cedeplar). Avenida Presidente Antônio Carlos, 6627, Pampulha, Belo Horizonte, MG, CEP 31270-901, Brasil. 0000-0002-0092-7119

[§]Bacharelando em Estatística na UFPE e estagiário no Núcleo de Estudos em Estatísticas Sociais da Fundação Joaquim Nabuco. 0000-0003-2525-6689

luis.campos@fundaj.gov.br

This is an open-access article distributed under the terms of the Creative Commons Attribution License.

Recebido em 17 de dezembro de 2018
Aceitação final em 16 de agosto de 2019

com que apenas jovens advindos de melhores escolas (em geral privadas e caras) pudessem completar o ensino superior de forma gratuita. As poucas universidades privadas de alta qualidade eram caras, o que também impedia o acesso dos jovens de classes inferiores de renda (Schwartzman, 2014; Corbucci, Kubota, & Meira, 2016).

Uma resposta a este problema foi a criação do crédito educativo em 1976. Contudo, o alto processo inflacionário, a baixa capacidade de investimento pelo estado e as dificuldades de pagar o financiamento ao término do curso limitavam o número de contratos, fazendo com que os resultados do crédito educativo para a expansão da oferta de ensino superior fossem pequenos. O Fundo de Financiamento Estudantil (FIES) surge em 1999, retomando o crédito educativo em um ambiente de controle da inflação, redução de taxas de juros e escolha do estado de incentivar o ensino superior pela via privada (Corbucci et al., 2016). No entanto, até 2010 a expansão do Fies não era muito significante, principalmente pela exigência de fiadores e taxas de juros que, apesar de baixas para o mercado financeiro, eram elevadas em termos absolutos. Somente a partir de 2010, com alterações substanciais nas regras de concessão é que o FIES passa a ter um importante papel na expansão da oferta de ensino superior no Brasil.

A avaliação da efetividade do FIES já vem sendo um tema de destaque na literatura nacional. Alguns estudos buscam investigar o efeito do Programa em *outcomes* futuros, como empregabilidade e salários (Rocha, Ehrl, & Monastério, 2016), ou sobre acesso e abandono universitários (Machado, 2017; Pontuschkar, 2016). Outros trabalhos estudam o impacto do financiamento FIES sobre o comportamento das instituições privadas de ensino superior, sobretudo, em termos de valor da mensalidade e rentabilidade (Locateli, Souza, Behr, & Momo, 2017; Duarte & Mello, 2015). Com base no levantamento bibliográfico conduzido por esse estudo, ainda não foram identificados trabalhos que avaliassem o impacto do Programa sobre a escolha de cursos prioritários. Nesse contexto, o objetivo desse artigo é avaliar o cumprimento das metas do FIES quanto ao ingresso de alunos em cursos de duas áreas prioritárias do Programa, que constituem as graduações nos campos da saúde e educação/ensino. A estratégia empírica de identificação explora uma mudança de regra ocorrida no programa no ano de 2009 que reduziu os juros do financiamento de 6,5% para 3,5% ao ano, excetuando-se os cursos de educação e ensino que já se beneficiavam da taxa de reduzida desde o ano de 2006. A ideia central é que essa mudança de regra pode ser interpretada como um choque exógeno ao estudante capaz de reduzir as restrições ao crédito educacional[1] e, portanto, capaz de capturar o efeito do Programa FIES sobre a decisão de ingresso no ensino superior. O estudo utiliza dados do Censo do Ensino Superior e do Relatório Anual de Informações Sociais (RAIS) entre os anos de 2009 e 2014 e identifica o impacto do FIES comparando o efeito do financiamento antes e depois da mudança de regras ocorrida em 2009, por meio de modelos logit. Toda investigação empírica se restringe aos estados do Nordeste.

Além dessa introdução, o trabalho se desenvolve em mais quatro seções. A segunda seção oferece uma discussão sobre o programa FIES detalhando seu funcionamento, objetivos e descrevendo as mudanças de regras ocorridas ao longo de sua existência. A seção três apresenta as bases de dados utilizadas no artigo e o modelo

[1] A ideia central que justifica a oferta de subsídios educacionais é que as famílias são restritas ao crédito e, portanto, não investem o suficiente na educação de seus filhos (Becker, 1967).

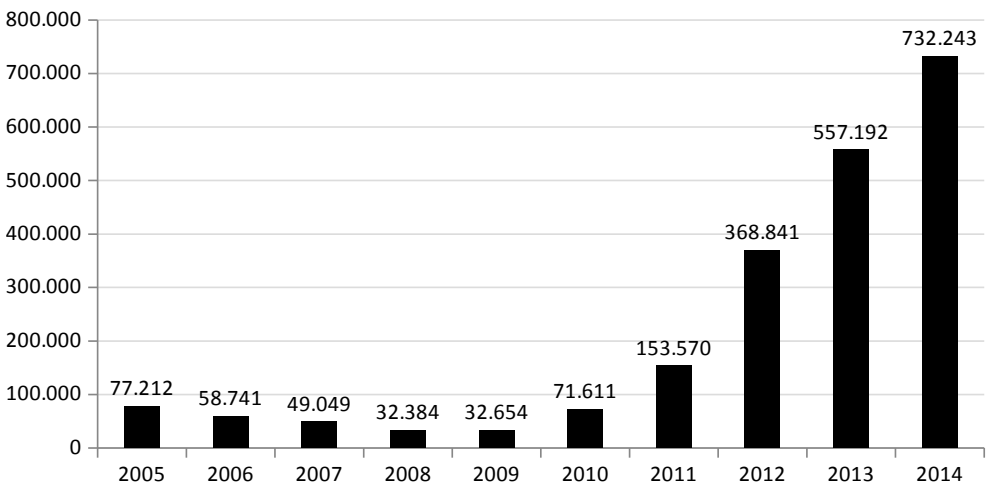
empírico a ser estimado. A quarta seção exibe os resultados com sua análise. Por fim, a última seção conclui o artigo em suas considerações finais.

2. O Programa FIES

O Governo FHC instituiu o Fundo de Financiamento ao Estudante do Ensino superior em 27/05/1999 por meio de medida provisória 1.827/1999, que foi reeditada até sua conversão na Lei Nº 10.260 de 12/07/2001. Na exposição de motivos desta medida provisória destaca-se meta de 60.000 financiamentos e defende-se a ideia de ascensão social e aumento de competitividade econômica do país. O FIES é vinculado ao Ministério da Educação sendo o FNDE responsável pela sua administração.

As receitas do FIES são formadas principalmente pelo orçamento do Ministério da Educação, trinta por cento das loterias e o próprio funcionamento do FIES. Mas também há outras: a totalidade dos recursos de premiação não procurados pelos contemplados dentro do prazo de prescrição da caixa econômica federal, encargos e sanções contratualmente cobrados nos financiamentos concedidos no âmbito do Programa de Crédito Educativo, rendimento de aplicações financeiras sobre suas disponibilidades, receitas patrimoniais e outras receitas.[2]

Desde sua fundação em 1999 o FIES passou por diversas e, algumas vezes, profundas transformações, porém somente a partir de 2010 é que o programa ganha proporções capazes de impactar a estrutura de mercado do ensino superior brasileiro (Corbucci et al., 2016). Na Figura 1 é possível ver que o FIES vinha diminuindo até 2009, provavelmente explicado pela crise econômica que elevou o desemprego e aumentou a incerteza para os trabalhadores, mas a partir de 2010 ocorre a forte expansão, devido ao conjunto regulatório que será detalhado a seguir.



Fonte: MEC – Relatórios de Gestão do FIES, diversos anos.

Figura 1. Contratos do Fies concedidos – Brasil (2005–2014).

[2] Recentemente houve alteração neste ponto. Contudo esta é a regra que valia para o momento de expansão, objeto de estudo deste artigo.

A Tabela 1 apresenta os cursos com o maior número de financiamentos. Nota-se que o setor de negócios (Direito, Administração de Empresas e Ciências Contábeis) predomina nas contratações. A educação está presente com pedagogia no sexto lugar do ranking. O conjunto de cursos da saúde possui mais contratações que a Engenharia.

De acordo com os textos oficiais do Ministério da Educação e do FNDE, o FIES consiste numa alternativa de acesso ao ensino superior por parte de jovens que não podem financiar seus estudos com sua própria renda no sistema privado. O discurso oficial incorpora, então, subliminarmente, duas ideias essenciais: i) o sistema financeiro é imperfeito e as famílias mais carentes estão restritas ao crédito; e ii) o Estado é incapaz de ampliar a oferta pública de vagas na velocidade necessária para as necessidades de pessoal qualificado.

O discurso é construído também no argumento de que o FIES pode contribuir para reduzir as disparidades educacionais que reforçam a desigualdade. Assim o programa apresenta regras que tentam corroborar esta visão, quais sejam: 1) financiamento de pessoas com renda per capita familiar abaixo de 2,5 salários mínimos;[3] 2) os cursos localizados nas regiões Norte, Nordeste e Centro-oeste, são beneficiados com financiamentos em maiores patamares que as outras regiões; 3) existência de áreas de conhecimento prioritárias. As regras 1 e 2 estão ligadas à questão da diminuição da concentração de renda entre as pessoas e entre as regiões, respectivamente.

Para entender como a regra 3 está ligada à redução das disparidades é preciso detalhar as áreas de conhecimento que são explicitamente escolhidas nos regulamentos e no discurso oficial. Os cursos prioritários são os pertencentes às áreas de: a) saúde; b) de formação de professores (licenciaturas, pedagogia ou normal superior); e c) das engenharias. A escolha da área de saúde como prioritária está embasada em diagnóstico de que há falta de oferta de profissionais da saúde e que a formação de pessoas na área poderia reduzir as disparidades de acesso à saúde. A escolha pela área de formação de professores também se baseia em diagnóstico de que um dos motivos para a baixa qualidade da educação brasileira está em forte carência de mão de obra qualificada.

Tabela 1. Dez Cursos Mais Financiados pelo FIES.

Curso	2010	2011	2012	2013	2014	2015	2016	Total Geral
Direito	13.654	26.529	56.207	85.921	110.512	46.932	26.986	366.741
Administração	5.038	11.061	35.080	48.723	55.521	16.678	11.026	183.127
Engenharia civil	3.430	9.448	25.623	41.498	57.760	25.129	16.113	179.001
Enfermagem	6.725	13.102	28.712	37.313	48.307	20.376	16.763	171.298
Psicologia	3.427	6.496	16.113	25.390	36.920	15.543	12.370	116.259
Pedagogia	1.315	5.201	19.779	27.793	30.132	8.992	5.058	98.270
Fisioterapia	2.628	5.581	13.010	19.062	28.615	13.017	10.391	92.304
Educação Física	2.072	4.667	12.212	20.896	30.605	11.070	9.685	91.207
Ciências Contábeis	2.183	5.240	15.775	22.491	28.127	9.699	6.980	90.495
Arquitetura e urbanismo	1.679	3.835	8.832	15.158	23.472	10.171	6.014	69.161

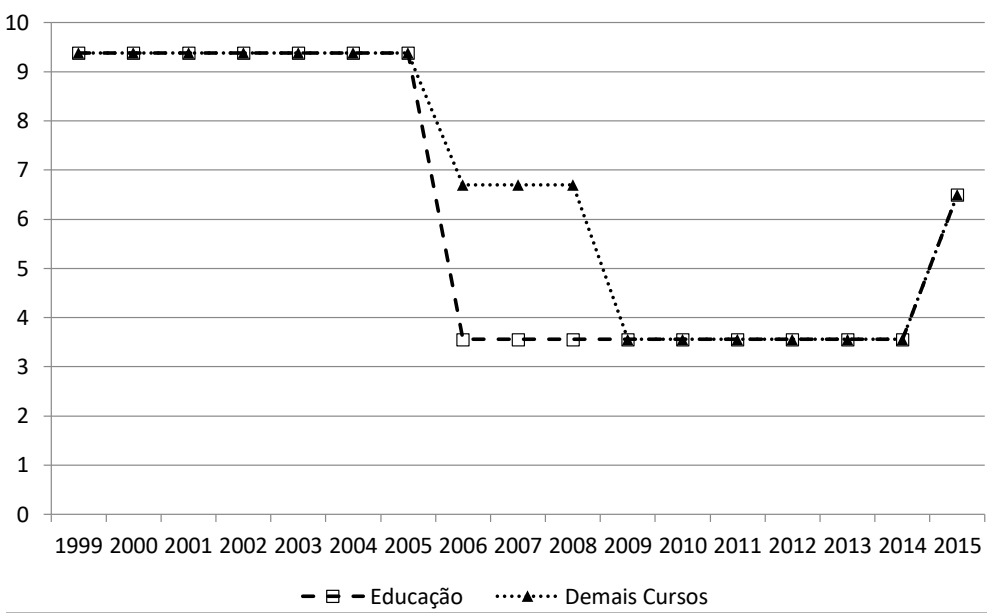
Font·: MEC (2017).

[3]Esta é uma das regras que sofrem ajustes frequentes. Esta estava em vigor no momento da grande expansão do início da década de 2010.

Já as engenharias seriam priorizadas com objetivo claro de buscar o aumento da produtividade do setor produtivo nacional.

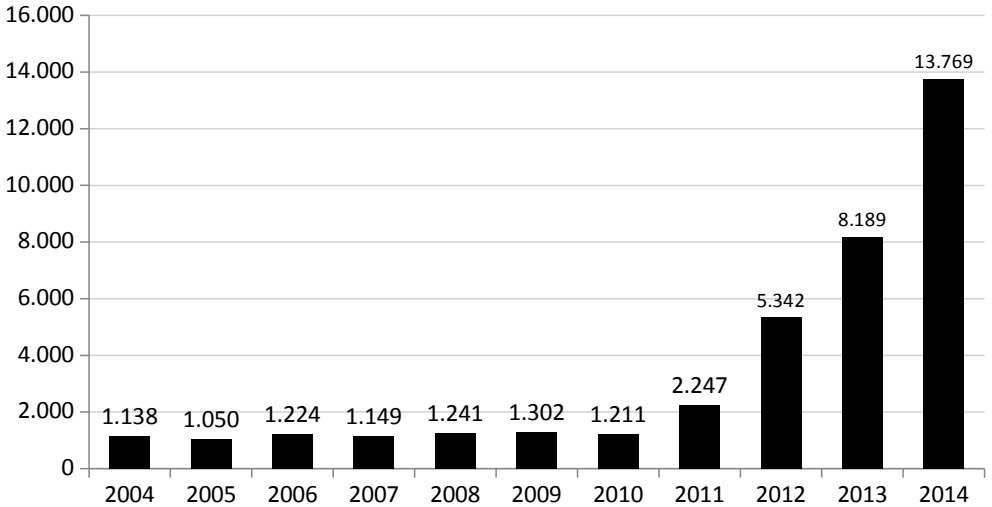
Assim, mais do que democratizar o ensino superior, o FIES é visto como um instrumento estratégico de desenvolvimento e redução de desigualdades de renda, regionais e de acesso a serviços públicos essenciais. Além de ser uma fonte alternativa de financiamento a pessoas que não teriam acesso ao sistema bancário comercial, com taxas de juros que viabilizam uma real atratividade para pessoas de baixa renda. Na Figura 2 é possível ver a evolução da taxa efetiva de juros cobrada pelo programa. Na criação do FIES ela era de 9,38% ao ano. Em 2006, alinhado com o objetivo do MEC de fomentar o acesso dos professores à graduação, a taxa se dividiu em duas partes: para os cursos de licenciatura, pedagogia, normal superior e cursos superiores de tecnologia, conforme definidos pelo catálogo de cursos superiores de tecnologia, a taxa era de 3,56% ao ano, enquanto que para os demais cursos era de 6,70% ao ano. Em agosto de 2009 as condições foram flexibilizadas e todos os cursos passaram a ser financiados à taxa de 3,5% ao ano, o que pode justificar o crescimento exponencial dos contratos observados a partir de 2010 (ver Figura 2). Por fim, em 2015, devido ao cenário fiscal e da necessidade de ajuste, e segundo a nota oficial visando manter "a sustentabilidade do programa, possibilitando sua continuidade enquanto política pública perene de inclusão social e de democratização do ensino superior" (BCB, 2015), a taxa voltou a ser de 6,5% ao ano para todos os cursos.

Na Figura 3 destaca-se a evolução dos gastos com o FIES no Brasil a partir de estudos do Congresso Nacional. Entre 2004 e 2010 o crescimento nominal dos gastos com FIES foi de 38,7%, o que corrigido pela inflação mostra quase estabilidade. Já a partir de 2010 os gastos sobem exponencialmente. De 2010 a 2014 o crescimento real



Fonte: Elaboração própria com base na legislação e portarias relativas ao FIES.

Figura 2. Evolução das Taxas efetivas de Juros.



Fonte: Mendes (2015).

Figura 3. Evolução das Despesas com o FIES (em milhões de R$ – a preços de 2014).

é de 1.037%. Os gastos chegam a R$ 13,8 bilhões em 2014. O que explica a necessidade do governo rever as normas em 2014 e manter uma política de revisões desde então.

As mudanças ocorridas ao longo do Programa, além de envolver fiança e taxa de juros também passaram pelos prazos envolvidos. A Tabela 2 mostra a trajetória histórica dos prazos de pagamento do FIES. É possível observar que o período de final de 2009 e final de 2013 há maior facilidade de pagamento, dada a menor taxa de utilização com o maior prazo de carência e maior prazo de amortização. Ou seja, taxa de juros subsidiadas, ampliação nos prazos de carência, de pagamento e retirada das diferenças de taxas por tipo de curso representam um conjunto de medidas que estimularam enormemente a procura pelo ensino superior. O pacote de contratação do período de 2010 a 2013 mostrou-se com grande elasticidade. Aliou-se a isto a decisão de Governo de ampliar os orçamentos do programa, levando a esta expansão.

Tabela 2. Alterações nas regras do FIES ao longo de sua vigência.

Formato	Taxa de utilização	Tempo de carência	Pagamento durante a carência	Tempo para amortização
FIES 99	Máximo de R$ 50,00 por trimestre	1 ano	Valor da mensalidade que antes pagava à faculdade	1,5 vezes o período do curso
FIES 06	Máximo de R$ 50,00 por trimestre	6 meses	Máximo de R$ 50,00 por trimestre	Nos 12 primeiros meses prestação igual ao valor da última mensalidade. Depois saldo devedor dividido em prestações iguais pelo prazo de 2 vezes o período do curso
FIES 09	Máximo de R$ 50,00 por trimestre	18 meses		3 vezes o período do curso + 12 meses
FIES 15	Máximo de R$ 150,00 por trimestre	18 meses	Máximo de R$ 150,00 por trimestre	3 vezes o período do curso

Ocorre que ao retirar as diferenças de taxas de juros e ampliar o escopo do programa desta forma levanta-se a questão: "Com essa configuração, como a meta de ampliar a oferta de profissionais das áreas de licenciaturas ou saúde pode ser atingida?" Ou em outros termos, a retirada de um incentivo adicional para que o aluno escolhesse licenciaturas ou saúde prejudicou o programa? Dois aspectos entram nas possíveis respostas. Por um lado a homogeneização das taxas juros pode diminuir a probabilidade do aluno escolher estas áreas, o que seria prejudicial ao cumprimento das metas do programa. Por outro lado, a forte expansão pode compensar e o volume de pessoas escolhendo estas atividades crescesse para atender às carências destacadas.

3. Modelo empírico e dados

3.1 Modelo empírico

O objetivo desse artigo é avaliar o cumprimento das metas do Programa FIES quanto ao ingresso de alunos em cursos de áreas prioritárias, que constituem as graduações nos campos da saúde, educação e ensino. Considerando que a elegibilidade ao financiamento estudantil é frequentemente correlacionada com outros fatores observáveis e não observáveis que também influenciam a escolha do curso superior, torna-se um desafio encontrar uma relação causal entre auxílio financeiro e a opção de curso.[4] Para lidar com essa questão, a estratégia de identificação adotada nesse artigo se baseia na mudança de regra do FIES ocorrida em 2009, que levou a uma homogeneização dos juros aplicados entre os cursos nas áreas de educação e ensino e os demais cursos.

Para avaliar o atendimento dos objetivos do FIES sobre a decisão de escolha de cursos em áreas prioritárias, será estimado o seguinte modelo logit de probabilidade linear com dados empilhados:

$$Y_{i,s,t} = \alpha + \beta Fies\&Ing2010_{i,s,t} + \gamma' Fies_{i,s,t} + \delta' Ingresso_{i,s,t} + \zeta' X_{i,s,t} + \eta Wagegap(Y)_{i,s,t} + \theta Capital_{i,s,t} + \vartheta' UF_{i,s,t} + \lambda' Ano_{i,s,t} + \varepsilon_{i,s,t}, \quad (1)$$

em que $Y_{i,s,t}$ representa o ingresso do estudante i na IES s no ano t em uma dada área prioritária. Duas áreas serão avaliadas, educação e saúde. Sendo assim, duas variáveis dependentes estão sendo consideradas em nossas análises: a primeira delas é uma dummy que assume o valor 1 para alunos matriculados em cursos de graduação na área de educação ou ensino e o valor 0 para estudantes dos demais cursos; a outra dependente em análise é uma variável dummy que assume o valor 1 para alunos matriculados em cursos de graduação na área de saúde e o valor 0 para os outros casos. *Fies* é um vetor de variáveis que representam dummies de recebimento do financiamento para cada ano do censo, da mesma forma que *Ingresso* é outro vetor de variáveis binárias indicando o ano de ingresso do aluno na IES em cada ano do censo. *Fies&Ing2010* é uma variável binária que representa a interação entre *Ingresso* e *Fies* e assume o

[4]Existe uma vasta literatura internacional que avalia os efeitos de subsídios educacionais sobre o comportamento do estudante e que propõem diversas metodologias para lidar com essas questões de endogeneidade (Urzua & Rau, 2012; Lochner & Monge-Naranjo, 2011; Belley & Lochner, 2007; Dynarski, 2003; Kane, 2003).

valor 1 quando o aluno ingressa no curso superior no ano de 2010 e, ao mesmo tempo, é contemplado pelo FIES nesse mesmo ano. O vetor X introduz a heterogeneidade exógena que captura as diferenças observáveis entre os indivíduos, incluindo sexo, idade, raça, recebimento de apoio social (alimentação, moradia, transporte, material didático, bolsa trabalho ou permanência), ingresso na IES por meio de reserva de vagas (quotas ensino público, étnico-racial, deficiência, renda familiar) e exercício de atividade acadêmica remunerada (pesquisa, monitoria ou extensão). A variável *Wagegap*(Y) representa a diferença entre o salário médio estadual da RAIS no setor prioritário em análise (saúde ou educação) e o salário médio das demais atividades de toda UF em que se localiza o curso do estudante. A introdução dessa variável no modelo visa a controlar para os incentivos do mercado de trabalho que também afetam a escolha pelo curso. O vetor *UF* é composto por dummies para cada estado da região Nordeste; *Capital* é uma variável binária igual a 1 para quando a IES do curso de graduação do aluno se localiza na capital do estado e, por fim, o vetor *Ano* representam dummies para cada ano do censo escolar, inseridas no modelo com o objetivo de capturar as demais especificidades ocorridas no ano que possam afetar a decisão de escolha do curso, sobretudo aquelas relacionadas à variação anual no número de contratos FIES que, como já mencionado, apresenta uma trajetória crescente desde 2009. A descrição dessas variáveis se encontra na Tabela 3.

O coeficiente β é o principal parâmetro de interesse desse estudo, pois denota o efeito do Programa sobre a escolha do curso entre aqueles alunos que ingressaram no ensino superior no ano seguinte às mudanças de regras do FIES de 2009. Note que a variável interada, quando assume o valor 1, representa o caso de um aluno que ingressou no ensino superior e ao mesmo tempo aderiu ao financiamento FIES, e o seu coeficiente captura justamente o efeito do Programa a partir da mudança exógena nas regras de contratação. Se o impacto do FIES é diferente nos períodos, antes e depois da mudança de regras, conclui-se então que o Programa afetou a escolha do curso universitário. Contudo, para que esta interpretação seja válida, o principal pressuposto exigido é que, além das variáveis de controle incluídas nos modelos estimados, a única diferença existente entre os dois períodos seja tão somente a mudança das regras. Note, entretanto, que os cursos da área de educação já se beneficiavam da taxa de juros reduzida antes mesmo de 2009 e, portanto, é de esperar que o efeito dessas alterações (que também incluem redução nos prazos do financiamento) repercutam de forma mais acentuada nos cursos da área de saúde.

3.2 Dados

O artigo utiliza dados provenientes de duas bases de dados, entre os anos de 2009 e 2014: Censo do Ensino Superior e RAIS. O Censo é uma pesquisa anual nacional que fornece informações sobre as instituições de ensino superior no Brasil, seus cursos de graduação, alunos e professores. Todas as informações disponíveis nesse levantamento são obtidas por meio de um questionário que todas as IES no Brasil devem preencher uma vez por ano. Embora Censo do Ensino Superior exista desde 1995, o artigo utiliza apenas os dados a partir de 2009, pois nessa versão foram coletadas diversas informações sobre características individuais dos alunos, incluindo sexo, raça, ano de ingresso na faculdade, financiamento FIES, dentre outros. Considerando ainda que

Tabela 3. Estatísticas descritivas das variáveis dos modelos.

Variáveis	Descrição	Média	Desvio padrão
Dependentes			
Educação	Dummy igual a 1 se o código de identificação da área geral do curso a partir da tabela OCDE for igual a 1 (Educação)	0,080	0,271
Saúde	Dummy igual a 1 se o código de identificação da área geral do curso a partir da tabela OCDE for igual a 7 (Saúde e bem estar social)	0,232	0,422
Independentes			
FIES_2009	Dummy igual a 1 se o aluno recebe FIES em 2009	0,001	0,035
FIES_2010	Dummy igual a 1 se o aluno recebe FIES em 2010	0,004	0,063
FIES_2011	Dummy igual a 1 se o aluno recebe FIES em 2011	0,011	0,103
FIES_2012	Dummy igual a 1 se o aluno recebe FIES em 2012	0,027	0,162
FIES_2013	Dummy igual a 1 se o aluno recebe FIES em 2013	0,050	0,218
FIES_2014	Dummy igual a 1 se o aluno recebe FIES em 2014	0,089	0,284
Ingresso em 2009	Dummy igual a 1 se o aluno ingressou no curso em 2009	0,203	0,402
Ingresso em 2010	Dummy igual a 1 se o aluno ingressou no curso em 2010	0,204	0,403
Ingresso em 2011	Dummy igual a 1 se o aluno ingressou no curso em 2011	0,188	0,391
Ingresso em 2012	Dummy igual a 1 se o aluno ingressou no curso em 2012	0,182	0,386
Ingresso em 2013	Dummy igual a 1 se o aluno ingressou no curso em 2013	0,142	0,349
Ingresso em 2014	Dummy igual a 1 se o aluno ingressou no curso em 2014	0,082	0,274
Sexo feminino	Dummy igual a 1 para sexo feminino	0,582	0,493
Cor branca	Dummy igual a 1 para cor branca	0,327	0,469
Cor preta	Dummy igual a 1 para cor preta	0,134	0,340
Cor parda	Dummy igual a 1 para cor parda	0,037	0,188
Idade	Idade que o aluno completa no ano de referência do Censo	26,829	8,057
IES na capital	Dummy igual a 1 se a IES está localizada na capital	0,702	0,457
Apoio social	Dummy igual a 1 se o aluno recebe algum tipo de apoio social	0,073	0,260
Reserva de vagas	Dummy igual a 1 se o aluno ingressou no curso por meio de reserva de vagas	0,002	0,043
Atividade remunerada	Dummy igual a 1 se o aluno exerce atividade remunerada de pesquisa, monitoria ou extensão	0,005	0,068
Wagegap (educação)	Diferença entre o salário médio estadual da RAIS no setor de educação e o salário médio das demais atividades na UF	-0,187	0,156
Wagegap (saúde)	Diferença entre o salário médio estadual da RAIS no setor de educação e o salário médio das demais atividades na UF	-0,107	0,167
Nº obs.	3.987.030		

Fonte: Elaboração própria com base nos microdados do Censo do Ensino Superior e da RAIS, 2009 a 2014, Região Nordeste.

o objetivo desse estudo é avaliar o alcance de metas do FIES na região Nordeste, a amostra ficou restrita apenas às instituições privadas de ensino superior do Nordeste, as quais possuem graduandos elegíveis para solicitar o financiamento.

Além do Censo do Ensino Superior o artigo também utiliza dados da RAIS, entre 2009 e 2014. A RAIS é uma pesquisa anual nacional conduzida pelo Ministério do Trabalho, em que as empresas do setor formal da economia são legalmente obrigadas a relatar uma série de informações sobre seus funcionários registrados com carteira assinada. Dessa pesquisa, o artigo utiliza os dados de salário médio por UF e nos setores selecionados para nossas análises, as quais incluem as atividades de educação e ensino e aquelas relacionadas à saúde. A Tabela 3 apresenta as variáveis selecionadas para estimações deste artigo.

As variáveis dependentes revelam que, apesar dos incentivos do programa, é baixo o percentual de alunos que escolhe a área de educação. O conjunto de *dummies* "FIES" revela o incrível crescimento da adesão do programa, pois em 2014 8,9% dos alunos das IES privadas do Nordeste estavam com contratos em andamento. A variável *Ingresso* mostra como a restrição orçamentária de 2014 afetou a entrada de novos alunos.

A maior parte da base é composta de mulheres e, ao contrário das características dominantes da sociedade nordestina, a predominância é da cor branca. A média etária é mais elevada do que seria esperada para a estrutura educacional brasileira, revelando que há busca das pessoas em diminuir seu *gap* educacional. A oferta privada ainda é bastante concentrada nas capitais. As variáveis do *gap* salarial mostram que o mercado de trabalho valoriza menos as ocupações de saúde[5] e, principalmente, educação.

4. Resultados

Esta seção apresenta os resultados das estimações dos modelos logit empilhados para o impacto do FIES sobre a dinâmica da expansão dos alunos das áreas de educação e saúde. Todos os resultados estão resumidos nas Tabelas 4 (educação) e 6 (saúde). Em ambos os casos, três modelos distintos foram estimados em ordem crescente de regressores. Na especificação 1 mais simples, não foram consideradas quaisquer variáveis de controle que capturassem as heterogeneidades individuais dos estudantes, nem as especificidades regionais. Na especificação 2 agregam-se as características dos alunos e, por fim, na especificação 3 mais completa, consideram-se as *dummies* de UF, de IES na capital e o *gap* salarial. Como de costume, relata-se o odds ratio das respectivas variáveis.

A Tabela 4 apresenta os resultados do impacto FIES sobre a decisão de escolher algum curso na área de educação. Para as três especificações testadas, o coeficiente da variável interada *Fies&Ing2010* demonstra que a mudança das regras reduziu a probabilidade do aluno escolher a área de educação, revelando que a homogeneização das regras do programa atrapalham para que os objetivos iniciais do mesmo sejam alcançados. Por outro lado, a variável *Ingresso*2010 mostra que a probabilidade de escolher educação aumenta, ou seja, o efeito do tamanho de mercado. Em outras

[5] A exceção seria a área de Medicina, que historicamente possui os salários mais elevados. Todavia, os estudantes de medicina na amostra investigada nesse artigo representem apenas 4% de todos os graduandos da área de saúde.

Tabela 4. Estimativas da probabilidade de ingresso em cursos na área de educação e ensino.

	Variável dependente: educação/ensino		
	1	2	3
Fies&Ing2010	0,538***	0,562***	0,603***
	(0,022)	(0,022)	(0,023)
Fies2010	0,462***	0,440***	0,469***
	(0,019)	(0,019)	(0,021)
Ingresso2010	0,972***	1,014***	1,051***
	(0,006)	(0,006)	(0,006)
Wagegap (educação)	–	–	1,070
			(0,049)
FIES (dummies de recebimento por ano)	Sim	Sim	Sim
Ingresso (dummies de ano de ingresso)	Sim	Sim	Sim
Ano do censo (dummies por ano)	Sim	Sim	Sim
Controles individuais	Não	Sim	Sim
Dummy IES se localiza na capital	Não	Não	Sim
Dummies UFs	Não	Não	Sim
Pseudo R^2	0,008	0,071	0,101
Nº observações	3.987.030	3.987.030	3.987.030

Notas: Desvio padrão entre parênteses. As dummies de referências são: Fies2009, Ingresso2009, Censo2009 e a UF Bahia. As estimativas completas podem ser obtidas com os autores.
*significante a menos de 10%; **significante a menos de 5%; ***significante a menos de 1%.

Tabela 5. Tabela de contingência para o modelo de Educação.

		Estimado			
		0		**1**	
		N	%	n	%
Observado	**0**	3.184.168	61,756	1.582.513	30,692
	1	129.698	2,515	259.711	5,037

palavras, mesmo com um tamanho de mercado relativamente maior, a homogeneização nas taxas de juros entre os cursos prioritários do Programa, gerou um desincentivo na escolha dos cursos de educação relativamente às demais áreas. Apesar de relevante para o modelo como um todo, o *gap* salarial não se mostrou significante, tal como ilustrado na especificação 3 da Tabela 4, o que pode ser consequência de multicolinearidade com as dummies estaduais, uma vez que foi suposto que cada estado comporia um mercado de trabalho individual.

Para averiguar a qualidade do modelo apresentado na Tabela 4 foi realizado o estudo de sua performance. A criação do modelo classificador considerou a proporção de alunos com opção em educação no banco de dados, de 0,076. A Tabela 5 representa a tabela de contingência elaborada a partir deste exercício. O modelo apresentou

acurácia de 66,8% e uma taxa de verdadeiros positivos de 66,7% o que leva à conclusão de robustez do modelo exposto na Tabela 4.

A Tabela 6 apresenta os resultados da estimação para a escolha dos cursos de saúde. Os resultados são significativamente diferentes daqueles da educação. As mudanças de regra levaram a que aumentasse a probabilidade de escolha desta área. Ao mesmo tempo, a dimensão de mercado atua em sentido oposto. Isto talvez ocorra pelo fato de que muitas pessoas que já estavam cursando esta área tenham aderido ao FIES após as alterações de 2009, como pode ser visto pelo elevado coeficiente do odds ratio da variável Fies2010. O gap salarial, dessa vez, demonstrou que os incentivos do mercado de trabalho aumentam as chances de escolha de cursos da saúde, sempre que o hiato em relação às demais áreas for positivo.

Assim como com o modelo para Educação, foi elaborada tabela de contingência para a Saúde. A proporção de alunos com opção em saúde no banco de dados, de 0,239. A Tabela 7 representa a tabela de contingência elaborada a partir deste exercício. O modelo apresentou acurácia de 63,32% e uma taxa de verdadeiros positivos de 66,2% o que leva à conclusão de robustez do modelo exposto na Tabela 6.

Em síntese, tomados conjuntamente, os resultados revelam que as alterações ocorridas no Programa foram eficazes para os cursos prioritários de saúde, mas geraram um desincentivo para aqueles da área de educação. A homogeneização das taxas de juros entre os cursos de educação e os demais cursos agiu como uma dose excessiva de "remédio", de forma a atrair alunos para outras graduações em detrimento dos cursos

Tabela 6. Estimativas da probabilidade de ingresso em cursos na área de saúde.

	Variável dependente: saúde		
	1	2	3
Fies&Ing2010	1,300***	1,316***	1,319***
	(0,018)	(0,019)	(0,019)
Fies2010	2,725***	2,696***	2,582***
	(0,048)	(0,050)	(0,048)
Ingresso2010	0,892***	0,874***	0,884***
	(0,004)	(0,004)	(0,004)
Wagegap (saúde)	–	–	2,672***
			(0,068)
FIES (dummies de recebimento por ano)	Sim	Sim	Sim
Ingresso (dummies de ano de ingresso)	Sim	Sim	Sim
Ano do censo (dummies por ano)	Sim	Sim	Sim
Controles individuais	Não	Sim	Sim
Dummy IES se localiza na capital	Não	Não	Sim
Dummies UFs	Não	Não	Sim
Pseudo R^2	0,020	0,071	0,082
Nº observações	3.987.030	3.987.030	3.987.030

Notas: Desvio padrão entre parênteses. As dummies de referências são: Fies2009, Ingresso2009, Censo2009 e a UF Bahia. As estimativas completas podem ser obtidas com os autores.
*significante a menos de 10%; **significante a menos de 5%; ***significante a menos de 1%.

Tabela 7. Tabela de contingência para o modelo de Saúde.

		Estimado			
		0		**1**	
		N	%	n	%
Observado	**0**	2.399.089	46,528	1.526.443	29,604
	1	416.329	8,074	814.329	15,793

de educação. Assim, como as graduações de educação já se beneficiavam de uma taxa de juros reduzida antes mesmo de 2009, o efeito das alterações nas regras do FIES (que também incluem redução nos prazos do financiamento) repercutiram de forma mais acentuada nos cursos da área de saúde.

5. Conclusões

Para encerrar a análise é importante visualizar o processo de concessão dos financiamentos. Os alunos se cadastram em sistema online do FNDE, que roda algoritmos de concessão. Estes consideram as diretrizes do Fundo. Assim, cursos com maior demanda que não estão entre as prioridades apresentam maiores taxas de recusa, por atingirem os tetos de concessão. Ao mesmo tempo, se os cursos prioritários não ocuparem toda a oferta de financiamentos há reescalonamento. Isto explica porque áreas não prioritárias são tão mais atendidas pelo FIES.

Como a base de dados utilizada está em nível individual (do aluno) o artigo contribui para determinar como o desenho do modelo pode interferir na demanda que é registrada pelos alunos no sistema antes de serem processados os algoritmos. Então, redução na probabilidade de escolha de uma área prioritária indica mudança equivocada no desenho da política.

Os resultados das estimações revelaram que a mudança das regras no FIES efetivadas em 2010 reduziram a propensão das pessoas em escolher cursos da área de educação levando à conclusão que as alterações foram em sentido contrário às metas explícitas. Ao mesmo tempo, a fortíssima expansão do programa compensou a redução da probabilidade de escolha por cursos na área de educação. Conforme pode ser visto na Tabela 1 de 2010 a 2014 houve um incremento de 2.191% no volume de estudantes de pedagogia atendidos pelo FIES. Já quando se analisa os dados da saúde o resultado é o oposto, com a mudança de regras de 2010 ampliando a probabilidade de escolha desta área. O crescimento nos vários cursos de saúde ranqueados da Tabela 1 foi de 231%, bem inferior ao encontrado em educação, o que explica o efeito negativo na variável Ingresso.

Por fim, cabe destacar que as alterações realizadas no FIES desde 2014 são no sentido de manter homogêneas as regras de taxa de juros e pagamento, o que tende a manter os efeitos danosos da mudança de 2010 sobre a decisão dos jovens em escolher carreiras ligadas à educação. A preocupação dos ajustes do FIES estão mais no sentido de restringir os gastos a um nível sustentável, deixando de lado uma estrutura de incentivos que realmente respeite os objetivos explicitados no desenho da política.

Referências bibliográficas

BCB – Banco Central do Brasil. (2015). *Resolução nº 4432: Fixa a taxa efetiva de juros do fundo de financiamento ao estudante do ensino superior (FIES)*. http://www.bcb.gov.br/pre/normativos/res/2015/pdf/res_4432_v1_O.pdf

Becker, G. S. (1967). *Human capital and the personal distribution of income: An analytical approach*. Ann Arbor, Institute of Public Administration. (Woytinsky lecture, no. 1)

Belley, P., & Lochner, L. (2007). The changing role of family income and ability in determining educational achievement. *Journal of Human Capital*, *1*(1), 37–89. http://dx.doi.org/10.1086/524674

Corbucci, P. R., Kubota, L. C., & Meira, A. P. B. (2016). Evolução da educação superior privada no Brasil: Da reforma universitária de 1968 à década de 2010. *Radar* – Ipea(46). http://repositorio.ipea.gov.br/handle/11058/7066

Corseuil, C. H. (Org.). (2002). *Estrutura salarial: Aspectos conceituais e novos resultados para o Brasil*. Brasília: IPEA. https://www.ipea.gov.br/portal/index.php?option=com_content&view=article&id=5438

Duarte, I. F., & Mello, J. M. P. (2015, 16 de outubro). Student loans impacts on tuition costs: Consequences of FIES. *In* C. G. Machicado (Chair), *XX Annual Meeting of the Latin American and Caribbean Economic Association (LACEA)*, Santa Cruz de la Sierra.

Dynarski, S. M. (2003). Does aid matter? Measuring the effect of student aid on college attendance and completion. *American Economic Review*, *93*(1), 279–288. http://dx.doi.org/10.1257/000282803321455287

Kane, T. J. (2003, maio). *A quasi-experimental estimate of the impact of financial aid on college-going* (Working Paper Nº 9703). Cambridge, MA: National Bureau of Economic Research (NBER). http://dx.doi.org/10.3386/w9703

Locateli, G. D., Souza, A. R. L., Behr, A., & Momo, F. S. (2017). Impacto do fundo de financiamento ao estudante do ensino superior na rentabilidade das empresas do setor educacional. *Revista de Administração, Ciências Contábeis e Sustentabilidade*, *7*(2). http://dx.doi.org/10.18696/reunir.v7i2.482

Lochner, L. J., & Monge-Naranjo, A. (2011, setembro). *Credit constraints in education* (Working Paper Nº 17435). Cambridge, MA: National Bureau of Economic Research (NBER). http://dx.doi.org/10.3386/w17435

Machado, I. P. (2017). *Efeitos do financiamento federal aos estudantes no acesso e na qualidade do ensino superior no Brasil* (Dissertação de mestrado, Insper, São Paulo). http://hdl.handle.net/11224/1760

MEC – Ministério da Educação. (2017). *ProUni e Fies reforçam a formação de professores*. Acessado em 15 mar 2017: http://portal.mec.gov.br/setec-secretaria-de-educacao-profissional-e-tecnologica/40-perguntas-frequentes-911936531/prouni-1484253965/7112-sp-1748592060

Mendes, M. (2015). A despesa federal em educação: 2004–2014. *Boletim Legislativo*(26). https://www12.senado.leg.br/publicacoes/estudos-legislativos/tipos-de-estudos/boletins-legislativos/bol26

Pontuschkar, R. (2016). *Avaliação do impacto do FIES* (Dissertação de Mestrado, Escola Superior de Agricultura "Luís de Queiroz", Piracicaba). http://dx.doi.org/10.11606/D.11.2016.tde-03102016-163218

Rocha, W. M., Ehrl, P., & Monastério, L. M. (2016, dezembro). Análise de impacto do FIES sobre o salário do trabalhador formal. *In 44° Encontro Nacional de Economia – Anpec*, Foz do Iguaçu. https://www.anpec.org.br/encontro/2016/submissao/files_I/i13-7a36172c5226550887c715fc5efc85dc.pdf

Schwartzman, S. (2014). A educação superior e os desafios do século XXI: Uma introdução. *In* S. Schwartzman (Org.), *Educação superior na América Latina e os desafios do século XXI* (pp. 15–44). Campinas: Editora da UNICAMP.

Urzua, S., & Rau, T. (2012, junho). Higher education dropouts, access to credit, and labor market outcomes: Evidence from Chile. *In* F. Buera & N. Fuchs-Schündeln (Chair), *SED Annual Meeting 2012*, Limassol, Chipre. https://ideas.repec.org/p/red/sed012/228.html (Meeting Papers No. 228)

r b e
REVISTA BRASILEIRA DE ECONOMIA
DOI 10.5935/0034-7140.20200009
ISSN 1806-9134 (online)
FGV
FUNDAÇÃO GETULIO VARGAS

A Note on the Effect of Decomposing Credit for Explaining Brazilian Cross-State GDP Growth*

Paulo Matos†
Davi Albuquerque V. Santos‡

Contents

1. Introduction 155
2. Literature on GDP Growth . 156
3. Methodology 157
4. Empirical Exercise 159
5. Concluding Remarks 164

Keywords
Credit, trade, government spending, growth

JEL Codes
049, 0230

Abstract · Resumo

Este artigo agrega à literatura sobre sistema financeiro e desenvolvimento ao propor um exercício empírico que visa entender os canais através dos quais as variáveis de crédito são capazes de promover o crescimento econômico. Estima-se uma um painel em diferença de uma versão ampliada da modelagem de crescimento a la Barro. Mensura-se assim, o impacto individual do crédito para famílias, para empresas e para o governo no crescimento do PIB dos estados brasileiros entre 2003 e 2017, controlando por: exportações, importações, anos de estudo, capital do governo e despesas correntes. Os resultados sugerem que o crescimento dos estados depende mais da evolução do crédito para famílias do que para empresas. Segundo esta evidência, é útil estudar o comportamento desse importante fator de crescimento econômico, uma vez que este crédito é insolvente. Destaca-se ainda o papel negativo desempenhado pelo crédito concedido aos governos estaduais, caracterizado por uma elasticidade de −0.87.

1. Introduction

It seems imperative to study the Brazilian cross-state growth. Observing the period from 2003 to 2017, while the state of Piauí shows an average annual growth rate higher than 5.6%, states in the North region such as Rondônia, Acre and Amazonas have grown at average rates lower than 0.8%. The robust and persistent heterogeneity in terms of Gross Domestic Product (GDP) can be exemplified by the extremes. In the Federal District and São Paulo, the average real per capita GDP (in constant R$ in December 2017) are R$74,500 and R$43,600, respectively, while in Piauí this value is

*Matos gratefully acknowledges financial support from CNPq-Brazil. Santos gratefully acknowledges financial support from CAPES-Brazil. For helpful comments on earlier drafts, we thank Emerson Marinho, Flávio Ataliba, Giovanni Beviláqua and Jaime de Jesus Filho. Also, we thank seminar participants at various institutions and conferences and the anonymous referees for relevant remarks. All errors are ours.

†Universidade Federal do Ceará, Programa de Pós-Graduação em Economia (UFC/CAEN). Avenida da Universidade, 2.760, Fortaleza, CE, CEP 60020-181, Brazil. 0000-0002-3566-525

‡Universidade Federal do Ceará, Programa de Pós-Graduação em Economia (UFC/CAEN). Avenida da Universidade, 2.760, Fortaleza, CE, CEP 60020-181, Brazil. 0000-0001-9766-2016

paulomatos@caen.ufc.br d_avs@caen.ufc.br

This is an open-access article distributed under the terms of the Creative Commons Attribution License.

Received on Feb 5th, 2019
Final Acceptance on May 27th, 2019

lower than R$10,400. Moreover, the poorest states are also more unequal, except for the Distrito Federal, which has the lowest poverty indicator and the highest income inequality coefficient. To make the scenario worse, the numbers remain worrying if we analyze data on human capital, infrastructure, housing, health, demography, and mainly credit.[1] This context motivates us to measure the role of the financial sector in the heterogeneous cross-state growth in Brazil.

In the quest towards the drawing of public policies in Brazil able to promote development and help the poorer states by accelerating growth and by reducing income inequality, we provide evidence for the recent and worrying Brazilian cross-state experience. We enter the debate on banking system and development by revisiting the classical growth panel regressions in difference. More specifically, we disentangle the mechanisms through which credit to firms, household and government explain the Brazilian cross-state growth from 2003 to 2017, controlling for exports, imports, years of schooling, besides government capital and current expenditures.

Regarding the variables in the set of conditioning information, it is worrying the level of government capital spending in relation to current spending and its cross-state dispersion. Average values from 2004 to 2017 of capital expenditure to GDP ranges from 0.8% in Paraná to 8.1% in Acre, while current expenditures to GDP oscillate between 7.3% in Santa Catarina and more than 29% in Acre. Also, aggregating exports and imports does not seem appropriate. In São Paulo, average exports as a ratio to GDP is lower than 0.3% and in Pará such rate assumes almost 30%. Concerning imports to GDP, in Acre we find an average ratio lower than 0.1% and in Amazonas higher than 33%.

To the best of our knowledge, there is no previous evidence on the measure of the effect of decomposing credit for explaining Brazilian cross-state growth, controlling for a broad set of macroeconomic variables. Our main findings suggest that Brazilian cross-state growth depends more on the evolution of household credit than on credit to firms. This note has important implications for Brazilian policy makers aiming to make more effective policies.

This note is structured as follows. In the section 2 there is a review of the literature, while section 3 illustrates the setup of the methodology. Section 4 analyzes the dataset and reports main findings. Section 5 is devoted to the discussion on public policies and final remarks.

2. Literature on GDP Growth

Since Solow's (1956) neoclassical growth model, many empirical studies have tried to find out which variables are able to drive long-run economic growth. This literature has proposed models to verify the existence of robust correlations or causalities between economic growth and sets of structural, demographic, political, institutional and financial variables, that will lead countries, states and cities to economic convergence to their steady-state.

[1] Concerning the financial system, according to Matos, Vasconcelos, and Penna (2013) there is a discriminatory credit policy evidenced by the formation of two clubs characterized by a regional bias. In short, Brazil is a continental country and with financial, macroeconomic and social differences, so that the aggregation of any variable can be seen ex ante as inadequate.

In the 80's, Feder (1983) added to this debate by finding a positive role played by exports to GDP on growth, while Barro (1991) has proposed to assess the role of government spending and human capital stock on economic growth of countries. These studies find that both variables are statistically significant, even using different proxy variables for human capital. Levine and Renelt (1992) try to shine a light on this discussion by incorporating investment, trade, fiscal and monetary variables into the model. Using Extreme-Bounds Analysis, they have found a positive impact of investment to GDP, human capital and trade to GDP.

Later on, De Gregorio and Guidotti (1995) have collaborated with the literature on finance and growth by including variables to assess possible effects of financial markets development, using total credit to the private sector as a share of GDP as proxy. However, in contrast to the empirical cross-country literature using aggregate credit measures, the theoretical related literature has already addressed the distinction between the role played by enterprise and household credit in economic growth. This contradiction has motivated researchers to assess whether some variables have independent impacts. More recently, Beck, Buyukkarabacak, Rioja, and Valev (2012) have explored empirically this specific issue. According to their main findings, the role played by the enterprise credit to GDP is positive and higher than household credit growth elasticity, for a sample of 45 developed and developing countries. This cross-country framework suggested by Beck et al. (2012) is the standard workhorse for our analysis of the effect of credit on cross-state growth in Brazil.

The literature on GDP growth in Brazil is quite large, since Brazilian inequalities and disparities offer a unique data set. In one of the first contributions, Ferreira (2000) has analyzed growth during the so-called "Brazilian Economic Miracle" through the beginning of Real Plan. His findings suggest that years of schooling and investment rates are able to promote growth. Investigating the role of government, Rocha and Giuberti (2007) disentangle current expenditure and capital, throughout the period 1986–2003. They have found a positive and significative correlation between capital expenditure and growth. When the current expenditure is partitioned into education, defense and communications spending, all of them seem to impact positively GDP growth. On the perspective of trade, Daumal and Özyurt (2011) have found that trade openness throughout the period from 1989 to 2002 is able to improve growth on Brazilian states that are more industrialized, with higher level of human capital and with higher stocks of private capital.

More aligned to our contribution, Galeano and Feijó (2012) have identified a statistically significant and positive correlation between total credit volume and GDP growth. In our paper, more specifically, we add to this empirical literature by using a dynamic balanced panel from 2003 to 2017. It enables us to measure the individual impact on the Brazilian cross-state GDP growth of household credit, enterprise credit and government credit, taking into account for decomposed macroeconomic variables used to control for human capital, trade and government consumption.

3. Methodology

We propose estimating dynamic panel regressions to assess some independent effects on the heterogeneous Brazilian cross-state per capita GDP growth. In other words,

we aim to measure the differential and independent impact, i.e. the significance and the sign of household credit, enterprise credit and government credit. Following the finance and growth literature, our set of conditioning information includes: (i) the log of initial real GDP per capita to control for convergence; (ii) years of schooling to control for human capital accumulation; (iii) the share of exports and imports to GDP; and (iv) the ratio of government current expenditure to GDP and the capital as a ratio of GDP. To control for endogeneity and omitted variable biases, our main conclusions are based on an instrumental variable difference-in-difference regressions.

In this context, our first regression has a limitation reported in the literature. Although theory predicts different effects of household and enterprise credit on GDP growth, many studies still use aggregate measures of overall bank lending to private sector. Thus, we estimate classical Barro-style growth regressions considering the data available for Brazilian sates of the following form:

$$GDP_{i,t} = \alpha GDP_{i,t-1} + \delta SCH_{i,t} + \gamma CRE_{i,t} + \theta GOV_{i,t} + \lambda TRA_{i,t} + \varepsilon_{i,t}, \qquad (1)$$

where the subscript i refers to each Brazilian entity among 27 states, and t to each year of our sample, from 2004 to 2017. Following this literature, in this standard regression GDP refers to Gross Domestic Product in log.[2] Our set of conditioning information includes: years of schooling given in log by SCH, overall bank credit to private sector relative to GDP denoted by CRE, the total government expenditure as ratio to GDP, GOV, and the ratio of exports and imports to GDP, indicated by TRA. As usual, refers to the residual.

Subsequently, we follow Beck et al. (2012) who have explored empirically the composition of bank lending to private sector across countries and its impact on GDP growth. Here we also propose a careful set of control variables by decomposing government consumption among current expenditures and capital and by decomposing trade in exports and imports. We measure the effect of such decomposition estimating the following regression:

$$GDP_{i,t} = \alpha GDP_{i,t-1} + \delta SCH_{i,t} + \lambda CRE_{i,t} + \theta_{\mathrm{CU}} CUR_{i,t} + \theta_{\mathrm{CA}} CAP_{i,t} + \lambda TRA_{i,t} + \varepsilon_{i,t}\,, \qquad (2a)$$

$$GDP_{i,t} = \alpha GDP_{i,t-1} + \delta SCH_{i,t} + \gamma CRE_{i,t} + \theta GOV_{i,t} + \lambda_{\mathrm{IM}} IMP_{i,t} + \lambda_{\mathrm{EX}} EXP_{i,t} + \varepsilon_{i,t}\,, \qquad (2b)$$

$$GDP_{i,t} = \alpha GDP_{i,t-1} + \delta SCH_{i,t} + \gamma_{\mathrm{HC}} HCR_{i,t} + \gamma_{\mathrm{EC}} ECR_{i,t} + \theta GOV_{i,t} + \lambda TRA_{i,t} + \varepsilon_{i,t}\,. \qquad (2c)$$

[2] We use GDP in log given non-stationarity issues, but we recognize the relevance of using well-known non-linear forms of growth.

The unique difference of the second regression is disentangling the government consumption among current expenditure to *GDP* (*CUR*) and the capital as a ratio of *GDP* (*CAP*). In the third regression, we disaggregate trade among imports to *GDP* and exports to *GDP*, given respectively by *IMP* and *EXP*. In the regression (2c) we try to replicate the contribution of Beck et al. (2012) for Brazilian cross-state by measuring the role of household credit to *GDP* given by *HCR* and of enterprise credit to *GDP* denoted by *ECR*.

Finally, our main novelty. We propose an extended model to better understand the GDP growth across Brazilian states. We claim that, to the best of our knowledge, we are the first to estimate this extended version of the framework suggested by Beck et al. (2012) useful to identify the role played by the effect of public sector credit, labeled by *GCR*, given our broad set of control variables. Our main findings are based on the estimation of the full model:

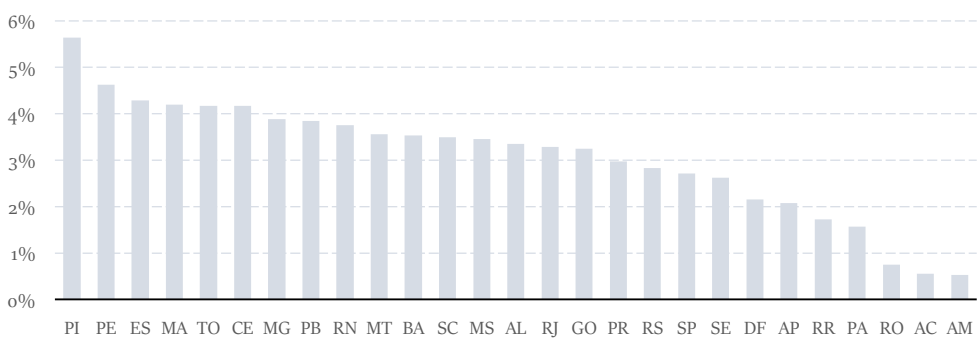
$$GDP_{i,t} = \alpha GDP_{i,t-1} + \delta SCH_{i,t} + \gamma_{\mathrm{HC}} HCR_{i,t} + \gamma_{\mathrm{EC}} ECR_{i,t} + \gamma_{\mathrm{GC}} GCR_{i,t} + \theta_{\mathrm{CU}} CUR_{i,t} + \theta_{\mathrm{CA}} CAP_{i,t} + \lambda_{\mathrm{IM}} IMP_{i,t} + \lambda_{\mathrm{EX}} EXP_{i,t} + \varepsilon_{i,t}. \quad (3)$$

4. Empirical Exercise

4.1 GDP Growth Data

We have extracted GDP data from Brazilian Institute of Geography and Statistics (IBGE). The series for each state were transformed into real per capita data using population, also extracted from IBGE and official Brazilian inflation measure, National Broad Consumer Price Index (IPCA). In Figure 1, we report GDP growth rate for each state.

Concerning this period, 13 states have an average lower than 3.3% per year, the national average. Most of them are located on the North region, with the exception of Distrito Federal (2.3%), São Paulo (2.7%) and Sergipe (2.6%). Also, in this figure, we can observe that most of the poorer states in Brazil, mainly on Northeast region are among those who have the highest growth rates, including Piauí with an average rate



Data source: IBGE.

Figure 1. Cross-state real per capita GDP growth (average from 2003 to 2017).

of 5.8% per year. However, it seems that this finding is not strong and robust enough to promote a convergence of real per capita GDP in Brazil.

4.2 Credit Data

We have extracted household and enterprise credit series from Central Bank of Brazil, while government credit is available on System of Accounting and Fiscal Information for the Brazilian Public Sector of the Secretary of National Treasure (SICONFI/STN). In Figure 2, we report minimum and maximum values for these credit variables for the states.

Brazilian government has stimulated household debt growth, without concerning to the level of human capital, profile of default or even employment status. Counterintuitively, household credit is reaching high levels even as loan interest rates are high and for the first time in December 2016 household credit has exceeded firm credit. Observing the minimum and maximum values for Brazilian states, during the 15 years of the sample, some patterns draw attention.

Following this evolution of household credit in the country, the amplitude observed in some states is very high. In the states of Paraíba and Goiás, such amplitude is 27% and 26%, respectively, followed by the northeastern states of Rio Grande do Norte and Sergipe, both with a 25% amplitude. The lower amplitude is observed in Amazonas, only 12%, where both the maximum and minimum values are also the smallest when compared to the other states.

Except for the amplitude of 32% registered in the state of Rio de Janeiro, all the other states present amplitude equal to or lower than 20%, when we observe the credit for firms in 2(b).

In general terms, the evolution of household credit in the poorest states, mostly located in the North and Northeast, seems to be stronger and more robust than the evolution of enterprise credit. In most of these states, household credit surpassed credit to the firms before December 2016, when such an event occurred in Brazil.

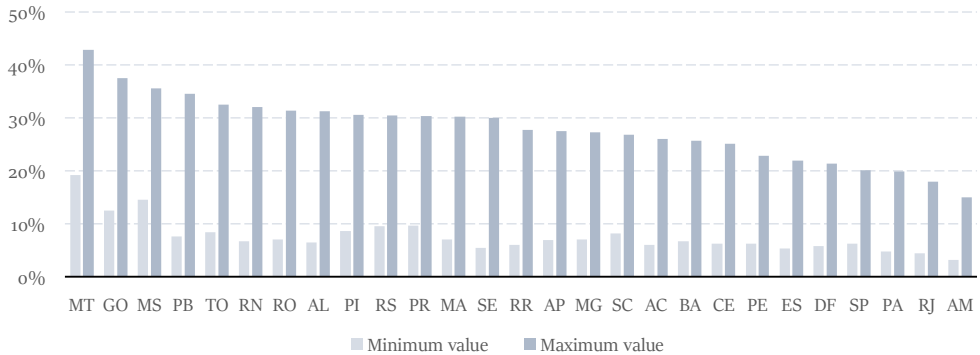
Observing the dispersion of credit to the state governments in the 2(c), a greater heterogeneity is visible in both the maximum and minimum values, as well as in the amplitudes. There also does not seem to be a pattern associated with localization, i.e. poorer states in a given region with a similar pattern.

4.3 Results

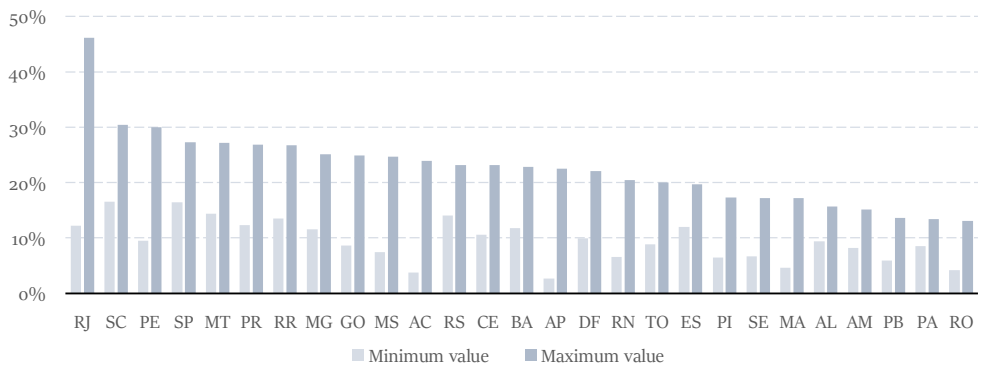
First, as a type of preliminary test we can see that all variables are stationary at 1%, except for Government Expenditures to GDP and both of its components, as Exports and Imports to GDP, although the latter it is stationary at 5%, according to the Table 1. We address this issue by applying the transformations suggested in Arellano and Bond (1991). Thus, we estimate growth regressions in difference, i.e. we take the first difference of the equations (1) to (3).

Our main findings are reported in Table 2.

First, we analyze the signal and the significance of the parameter associated with the lag of per capita GDP growth. In both the restricted and full models, we observe a robustness in the value of this parameter, which is significantly positive. According to this literature, a negative relationship between growth and GDP per capita in level



(a) Household credit to GDP



(b) Enterprise credit to GDP



(c) Government credit to GDP

Data source: IBGE, Central Bank of Brazil and Secretary of National Treasury.

Figure 2. Household, enterprise and government credit to GDP from 2004 to 2017.

Table 1. Panel unit root test.[a, b]

Real per capita GDP (in log)	−7.7414***	Government expenditures to GDP	−1.4480*
	[0.0000]		[0.0738]
Years of schooling (in log)	5.5267	Government capital expenditures to GDP	−2.0999**
	[1.0000]		[0.0179]
Overall banking sector credit to GDP	−8.8033***	Government current expenditures to GDP	−0.2262
	[0.0000]		[0.4105]
Household credit to GDP	−9.7125***	Exports and imports to GDP	−1.7618**
	[0.0000]		[0.0390]
Enterprise credit to GDP	−6.4273***	Exports to GDP	−11.9939***
	[0.0000]		[0.0000]
Government credit to GDP	−10.8679***	Imports to GDP	−2.9654***
	[0.0000]		[0.0015]

Notes: [a]Levin, Lin, and Chu (2002) panel unit root test with intercept over the period from 2004 to 2017 ($H0$: common unit root).
[b]Respective p-values are reported in brackets.
* p-value < 0.10; ** p-value < 0.05; *** p-value < 0.01.

could be suggesting a reversion to the mean pattern or GDP convergence. However, since we estimate the model using both variables in difference, the analysis of this parameter only suggests an inertial behavior in the cross-state growth.

Among the variables in the set of conditioning information, in all versions except for the model in the second column, we find no relationship between years of schooling and growth. This uncomfortable finding diverges from the previous findings for countries reported in most papers, maybe due to the proxy used to measure human capital stock.

Concerning government expenditure and trade, theoretical literature has addressed the distinction between the role played in economic growth by current expenditure and capital, as well as, exports and imports, in contrast to the empirical cross-country literature using aggregate measures. This contradiction has motivated us to disentangle such variables aiming to use them as control variables in the regression (full model). The first column shows us a negative and significant relationship between total government expenditure to GDP and growth, while the estimates of the full model suggests that capital and current spending are relevant and different drivers of cross-state growth in Brazil. We highlight the government capital and current expenditure elasticities of GDP growth, 1.01 and −1.75, respectively. According to Wald joint test, these impacts are statistically different.

The column [1] regression reports an insignificant role of trade to GDP corroborating the cross-country evidence reported in Beck et al. (2012). However, the column [5] regression suggests export and import elasticities of growth with close values, but with different signs. This evidence is robust, according to Wald test. Although national accounts define the signal of exports and imports in GDP in level, the evidence on the signs of their effects considering all these variables in difference is very scarce. A

Table 2. Results.[a, b, c, d]

Main results	[1] Restricted model	[2] Disaggregating governemnt expenditures	[3] Disaggregating trading variables	[4] Disaggregating credit (Beck et al., 2012)	[5] Full model
Control for convergence					
Real per capita GDP (lagged in log)	0.3973***	0.3895***	0.3565***	0.3969***	0.3109***
	[0.0000]	[0.0000]	[0.0000]	[0.0000]	[0.0000]
Control variables					
Years of schooling (in log)	−0.0262	0.1192**	0.0446	−0.1650	0.1814
	[0.6433]	[0.0368]	[0.7013]	[0.1112]	[0.2099]
Government expenditures to GDP	−0.6745***		−0.6055**	−0.7634***	
	[0.0000]		[0.0492]	[0.0003]	
Government capital expenditures to GDP		0.9841***			1.0128***
		[0.0000]			[0.0000]
Government current expenditures to GDP		−1.6080***			−1.7501***
		[0.0000]			[0.0000]
Exports and imports to GDP	−0.0269	−0.0227		−0.1248**	
	[0.3357]	[0.5031]		[0.0122]	
Exports to GDP			−0.7613***		−0.7614***
			[0.0000]		[0.0000]
Imports to GDP			0.9824***		0.7267***
			[0.0000]		[0.0000]
Credit variables					
Overall banking sector credit to GDP	0.8507***	0.7672***	0.8297***		
	[0.0000]	[0.0000]	[0.0000]		
Household credit to GDP				1.4071***	0.9126***
				[0.0000]	[0.0000]
Enterprise credit to GDP				0.3459***	0.2466*
				[0.0000]	[0.0516]
Government credit to GDP					−0.8658***
					[0.0000]
B. Wald joint tests					
$\gamma_{HC} = \gamma_{GC} = \gamma_{EC}$					61.4670***
					[0.0000]
$\gamma_{HC} = \gamma_{EC}$				30.8878***	11.2668***
				[0.0000]	[0.0009]
$\lambda_{IM} = \lambda_{EX}$			78.3112***		36.1545***
			[0.0000]		[0.0000]
$\theta_{CU} = \theta_{CA}$		30.5011***			36.8654***
		[0.0000]			[0.0000]
C. Complementary results					
Arellano–Bond test – AR(2)	−2.5643	−2.5160	−1.4298	−0.0008	−1.9234
	[0.0103]	[0.0119]	[0.1528]	[0.9994]	[0.0544]
Instrument rank	27	27	27	28	27
Sargan–Hansen test	26.1544	26.1530	24.6595	24.5903	20.9192
	[0.2451]	[0.2007]	[0.2622]	[0.3171]	[0.2835]

Notes: [a] Dynamic balanced panel with the 26 states and Federal District, from 2004 to 2017. [b] Arellano and Bond's (1991) efficient GMM estimate with fixed effects in the cross section and White's variance-covariance matrix in the temporal dimension. [c] Instrument set: lagged dependent variable (dynamic) and the respective lagged explanatory variables (level). [d] Respective p-values are reported in the brackets.

* p-value < 0.10; ** p-value < 0.05; *** p-value < 0.01.

conjuncture analysis able to explain such evidence is associated with a subsidized export pattern, capable of distorting relative prices and thus to impact negatively production, while importing may be characterized by the acquisition of capital goods, implying in future increase of productivity.

Finally, our main findings. In any of the estimated versions (1) to (2b), total credit to GDP positively affects growth. When we disentangle credit, both household and enterprise credit to GDP enter consistently with a positive coefficient. We also observe that F-test rejects the null hypothesis that the role of credit to firms is statistically similar to the role of household credit. Moreover, we are the first one to find that Brazilian cross-state growth depends more on the evolution of household credit than on credit to firms. We also highlight the negative role played by government credit to GDP given by the significant elasticity of −0.87. At least, the credit disbursement of US$28.6 billion from Brazilian National Economic and Social Development Bank (BNDES) to Brazilian state governments during the period from 2009 to 2014 has followed technical criterion, according to Matos and Jesus (2019).

As complementary results, we also report in Table 2 the results for Sargan–Hansen test for the overall validity of the instruments by analyzing the sample of the moment conditions used in the estimation process. We fail to reject the null hypothesis that such restrictions are valid for all five models. Moreover, following Arellano and Bond's (1991) test we fail to reject the null hypotheses of no autocorrelation of the error term for autoregressive process in the models (2b), (2c), and (3). While subject to the usual caveats of cross-state instrumental variable regression—bias due to lagged dependent variable, potentially weak instruments, weak tests of overidentifying restrictions and lack of instruments for other explanatory variables—our findings for the full model suggest that the relationship between enterprise and mainly household credit to GDP and growth is not driven by endogeneity, simultaneity or measurement biases.

5. Concluding Remarks

To summarize our analysis, regardless of the benefits due to household credit, we need to better understand the behavior of this insolvent economic growth driver, given its prominent role in the financial market and growth in Brazil.

Some empirical extensions that seem to be very relevant and informative are associated with the credit for households, taking into account for different financing sources: non-earmarked and earmarked. Even more relevant would be working with disaggregated series for the states of both sources, since agricultural credit and real estate credit should impact growth differently, as well as credit card may have a different impact from the vehicle credit. Other decompositions in this sense are credit for firms by production sector, or by size of firms in Brazil.

Still regarding the financial drivers of growth, incorporating variables able to capture the evolution of the Brazilian stock market can also be seen as a timely extension of this applied literature to Brazil. We find that the analysis of the financial source through equity capital by the companies for Brazilian state can be useful to better understand the role of the financial system in growth, through this other channel which is less explored than debt capital channel.

Moreover, concerning the control variables, the decomposition of the current expenditures of the government among its numerous items can also be very useful in this literature. The results reported in Orair, Siqueira, and Gobetti (2016) for the period from 2002 and 2016, for instance, suggest that the effect on GDP of the expenditure with social assistance and security benefits is higher than 1.5, while the response to personnel expenses assumes values between 1.2 and 1.33 in the months of greatest impact. In a context of excess of current expenditures—in 2017 18 units of the federation surpassed the so-called warning threshold of 44.1% for executive payroll expenses including retirees—some types of current spending are more relevant than others in the sense of promoting growth.

Finally, we should mention that our innovation does not compete with or rival the extensive literature on growth regressions. On the contrary, we invite theoretical and empirical researchers who have proposed or applied such theories to revisit cross-state growth and inequality by assuming this extended framework.

References

Arellano, M., & Bond, S. (1991). Some tests of specification for panel data: Monte Carlo evidence and an application to employment equations. *The Review of Economic Studies*, *58*(2), 277–297. http://dx.doi.org/10.2307/2297968

Barro, R. J. (1991). Economic growth in a cross-section of countries. *The Quarterly Journal of Economics*, *106*(2), 407–433. http://dx.doi.org/10.2307/2937943

Beck, T., Buyukkarabacak, B., Rioja, F. K., & Valev, N. T. (2012). Who gets the credit? And does it matter? Household vs. firm lending across countries. *The B.E. Journal of Macroeconomics*, *12*(1), 1–44. http://dx.doi.org/10.1515/1935-1690.2262

Daumal, M., & Özyurt, S. (2011). The impact of international trade flows on economic growth in Brazilian states. *Review of Economics and Institutions*, *2*(1), 1–25. http://dx.doi.org/10.5202/rei.v2i1.27

De Gregorio, J., & Guidotti, P. E. (1995). Financial development and economic growth. *World Development*, *23*(3), 433–448. http://dx.doi.org/10.1016/0305-750X(94)00132-I

Feder, G. (1983). On exports and economic growth. *Journal of Development Economics*, *12*(1), 59–73. http://dx.doi.org/10.1016/0304-3878(83)90031-7

Ferreira, A. (2000). Convergence in Brazil: Recent trends and long-run prospects. *Applied Economics*, *32*(4), 479–489. http://dx.doi.org/10.1080/000368400322642

Galeano, E. V., & Feijó, C. (2012). Crédito e crescimento econômico: Evidências a partir de um painel de dados regionais para a economia brasileira dos anos 2000. *Revista Econômica do Nordeste*, *43*(2), 201–219. https://ren.emnuvens.com.br/ren/article/view/213

Levin, A., Lin, C.-F., & Chu, C.-S. J. (2002). Unit root tests in panel data: Asymptotic and finite-sample properties. *Journal of Econometrics*, *108*(1), 1–24. http://dx.doi.org/10.1016/S0304-4076(01)00098-7

Levine, R., & Renelt, D. (1992). A sensitive analysis of cross-country growth regressions. *The American Economic Review*, *82*(4), 4–942. https://www.jstor.org/stable/2117352

Matos, P., & Jesus, J. d., Filho. (2019). On the drivers of BNDES credit to Brazilian state governments. *Journal of Financial Economic Policy*, *11*(2), 283–302. http://dx.doi.org/10.1108/JFEP-06-2018-0088

Matos, P., Vasconcelos, J., & Penna, C. (2013). Política creditícia no Brasil: O sertão vai virar mar? *Economia* (Anpec), *14*, 1–129.

Orair, R. O., Siqueira, F. d. F., & Gobetti, S. W. (2016). *Política fiscal e ciclo econômico: Uma análise baseada em multiplicadores do gasto público*. Tesouro Nacional. https://www.tesouro.fazenda.gov.br/documents/10180/558095/2o-lugar-rodrigo-octavio-orair-086.pdf (XXI Prêmio Tesouro Nacional)

Rocha, F., & Giuberti, A. C. (2007). Composição do gasto público e crescimento econômico: Uma avaliação macroeconômica da qualidade dos gastos dos estados brasileiros. *Economia Aplicada*, *11*(4), 463–485.

Solow, R. (1956). A contribution to the theory of economic growth. *The Quarterly Journal of Economics*, *70*, 65–94. http://dx.doi.org/?

r b e
REVISTA BRASILEIRA DE ECONOMIA
DOI 10.5935/0034-7140.20200010
ISSN 1806-9134 (online)
FGV
FUNDAÇÃO GETULIO VARGAS

O que Explica o Desempenho do Brasil no PISA 2015?

Giovanni Avila Cardoso Di Pietra[*]
Alex Hayato Sassaki[†]
Bruno Kawaoka Komatsu[‡]
Naercio Aquino Menezes Filho[§]

Sumário

1. Introdução 167
2. Revisão da Literatura 170
3. Descrição do PISA 2015.....171
4. Estratégia empírica de decomposição do desempenho .. 173
5. Decaimento.....176
6. Recuperação.....188
7. Conclusão e desenvolvimentos futuros..... 192
Apêndice. 196

Palavras-chave
Habilidades socioemocionais, habilidades cognitivas, PISA, desigualdade

JEL Codes
015, J24

Resumo · Abstract

This paper aims to explain the low performance of Brazil in PISA 2015, exploring innovations in the organization of the exam and introducing the effect of a break amidst an exam. We show that Brazilians have a performance decline throughout the exam and propose an alternative measure to the decay from a discontinuity in scoring chance between the break. Decay and discontinuity are plausible measures for differences in non-cognitive abilities. We argue that decay may be the result of students spending too much time on initial questions and not reaching the latter. Despite poor performance in non-cognitive indicators, Brazilian performance is mainly explained by the difficulty in initial questions, highlighting a disadvantage in cognitive abilities in relation to other countries. uma desvantagem nas habilidades cognitivas e/ou na experiência em fazer esse tipo de prova em computador com relação aos alunos dos outros países.

1. Introdução

A qualidade da educação no Brasil em comparações internacionais é ruim. Em 2015, o Brasil ficou na posição 59 a 66, dependendo da disciplina, de 73 regiões e países no Programa Internacional de Avaliação de Alunos (*Programme for International Student Assessment* – PISA), com médias de notas em matemática (401 pontos), leitura (407 pontos) e ciências (377 pontos) abaixo das médias dos alunos da OCDE (de respectivamente 493, 493 e 490 pontos). Essas médias não representaram melhora

[*]Fundação Getúlio Vargas, Escola de Economia de São Paulo (FGV/EESP). Rua Itapeva, 474, Bela Vista, São Paulo, SP, CEP 01332-000, Brasil. 0000-0003-1192-8501

[†]Insper, Cátedra Ruth Cardoso. Rua Quatá, 300, Vila Olímpia, São Paulo, SP, CEP 04546-042, Brasil. 0000-0002-2825-8711

[‡]Insper, Cátedra Ruth Cardoso. Rua Quatá, 300, Vila Olímpia, São Paulo, SP, CEP 04546-042, Brasil. 0000-0001-6045-9794

[§]Insper, Cátedra Ruth Cardoso; e Universidade de São Paulo, Faculdade de Economia, Administração e Contabilidade (USP/FEA). Av. Prof. Luciano Gualberto, 908, Butantã, São Paulo, SP, CEP 05508-010, Brasil. 0000-0003-1241-6188

di.pietra.giovanni@gmail.com asassaki@usp.br brunokk@insper.edu.br naercioamf@insper.edu.br

This is an open-access article distributed under the terms of the Creative Commons Attribution License.

Recebido em 04 de janeiro de 2019
Aceitação final em 16 de agosto de 2019

em relação aos últimos anos. A média brasileira de ciências tem se mantido estável desde 2006, e a de leitura, desde 2000. A média de matemática apresentou crescimento significativo de 21 pontos desde 2003, porém diminuiu 11 pontos entre 2012 e 2015 (OCDE, 2017).

Habilidades cognitivas e socioemocionais são determinantes para o desenvolvimento econômico de países ou regiões e para resultados socioeconômicos individuais. Medidas precisas de habilidades cognitivas baseadas em notas de exames internacionais padronizados, como as do PISA, têm mostrado que países com maiores níveis de habilidades cognitivas na população apresentam crescimento econômico mais acelerado (Hanushek & Kimko, 2000; Hanushek & Woessmann, 2012). Por outro lado, as diferenças de notas de exames entre os países representam não somente a diversidade de habilidades cognitivas, porém também a heterogeneidade de habilidades socioemocionais. As habilidades socioemocionais vem ganhando relevância na literatura econômica, uma vez que possuem papel importante dentro de avaliações padronizadas (Duckworth et al., 2009; Eklöf, 2007; Segal, 2012; Borghans, Duckworth, Heckman, & Ter Weel, 2008; Almund, Duckworth, Heckman, & Kautz, 2011) e, de forma mais geral, para o desempenho econômico e outros *outcomes* individuais (Heckman, Stixrud, & Urzua, 2006; Heckman, Pinto, & Savelyev, 2013; Balart, Oosterveen, & Webbink, 2018).

Nesse artigo, nós exploramos inovações na organização da prova do PISA de 2015 para examinarmos quais aspectos dessa avaliação são relacionados aos diferentes tipos de habilidades e quais deles determinam o desempenho relativamente ruim do Brasil. Em 2015, as provas realizadas em computador foram organizadas de modo que os alunos obrigatoriamente responderam à questões de forma sequencial: uma vez finalizada a questão, eles não poderiam retornar a ela. Dessa maneira, os alunos não puderam escolher responder em primeiro lugar somente as questões que sabiam responder.

Nós utilizamos os microdados do PISA 2015 para determinar medidas de habilidades cognitivas e socioemocionais. Em primeiro lugar, seguindo o procedimento em Borghans e Schils (2012), Balart et al. (2018) e Marchioni (2017), nós exploramos a variação exógena da posição de cada questão para identificar os efeitos de habilidades socioemocionais que se refletem no declínio de rendimento ao longo da prova, decompondo os resultados do PISA em duas dimensões: no desempenho inicial, que representa as habilidades cognitivas, e em variações no desempenho durante a prova, que representam habilidades socioemocionais. Dada a alocação aleatória da posição de cada questão, as diferenças na queda do desempenho ao longo de uma prova refletem aspectos individuais tais como persistência, concentração e determinação na população dos países.

Medidas baseadas em resultados objetivos de uma avaliação, como as aqui apresentadas, superam o caráter subjetivo de indicadores construídos a partir de informações auto relatadas, que limitam a comparabilidade entre indivíduos e regiões. Uma inovação metodológica proposta por este trabalho é levar em conta a influência do intervalo entre os blocos de provas para a estimação do decaimento do acerto ao longo da prova, obtendo resultados mais acurados para a probabilidade de acerto no início e no final do exame.

A medida tradicional de decaimento consiste em estimar a diferença entre a probabilidade de acerto na primeira questão e a probabilidade de acerto na última questão. Propomos neste trabalho uma medida alternativa, que explora a descontinuidade da probabilidade de acerto das questões ao redor do intervalo entre os dois blocos de provas, estimada com uma abordagem de RDD. Em geral, os alunos apresentam uma probabilidade de acerto muito baixa pouco antes do intervalo e uma alta probabilidade de acerto após o intervalo, semelhante à probabilidade de acerto no início da prova.

Nossos resultados mostram que, em comparação com alguns dos países que possuem as maiores médias do PISA, os alunos brasileiros possuem baixa probabilidade de acerto da primeira questão, o que pode indicar que as habilidades cognitivas também são menores. Além disso, a probabilidade de responder corretamente às questões vai se reduzindo ao longo dos dois blocos da prova. Entre esses dois blocos há um intervalo em que o Brasil também mostra uma recuperação acentuada.

Quais são as implicações desse padrão para a interpretação dos indicadores de habilidades socioemocionais? Para responder essa questão procuramos investigar com mais detalhes os determinantes do decaimento, com foco especial sobre a taxa de respondentes que chegam à questão e sobre o tempo de resposta médio utilizado em cada questão respondida. Promovemos uma discussão que sugere que o mal desempenho do Brasil se deve ao fato de que grande parte dos respondentes não conseguirem chegar ao fim da prova. Esse comportamento pode ocorrer pelo fato de que os jovens demoram para entender o enunciado da questão e para desenvolver o raciocínio sobre a resposta. Também pode ser que a tradução da prova seja mal feita, que os alunos brasileiros não estejam acostumados a fazer provas no estilo da prova do PISA ou ainda, que eles não estejam acostumados a fazer provas em computadores. Nesse sentido, a interpretação do decaimento como medida puramente de habilidades socioemocionais não parece muito clara, motivando a busca por uma outra medida que possa melhor capturar a influência destas habilidades.

Nossa segunda discussão apresentada se relaciona ao padrão de decaimento da probabilidade de acerto ao longo da prova como um todo. Parte do mal desempenho do Brasil parece ser devido à falta de habilidade em fazer uma prova no formato do PISA. Nós mostramos que o tempo médio de resposta das primeiras questões do bloco após o intervalo são consideravelmente menores do que aqueles das primeiras questões do primeiro bloco. Além disso, a probabilidade de chegar ao final do segundo bloco é consideravelmente maior do que a probabilidade de chegar ao final do primeiro bloco. Uma vez que a dificuldade das questões do primeiro bloco é igual àquela das questões do segundo bloco, os jovens brasileiros parecem aprender a fazer a prova ao longo da prova, o que não ocorre de forma tão acentuada em países com as maiores notas.

Apresentamos neste trabalho uma medida alternativa ao decaimento para capturar a influência das habilidades socioemocionais ao longo de uma prova, a descontinuidade de desempenho entre os dois blocos da prova. Nesta métrica, o Brasil apresenta a maior descontinuidade, em parte por um possível aprendizado ao longo da prova e outros fatores elencados acima. A interpretação desta medida como algo estritamente negativo e sua aplicabilidade para realizar comparações entre os países ainda não é clara. No entanto, ao replicarmos a metodologia de crescimento em Balart et al. (2018) e Hanushek e Woessmann (2012), apresentamos uma série de exercícios empíricos

sustentando o argumento de que a recuperação entre os blocos pode ser uma medida superior ao decaimento na representação das habilidades socioemocionais.

Além dessa introdução, a segunda seção traz uma revisão da bibliografia relevante para o desenvolvimento deste trabalho. A terceira seção descreve a estrutura do PISA 2015 e os dados utilizados e a quarta seção descreve a metodologia para estimação dos indicadores de habilidades socioemocionais a partir da decomposição do desempenho no PISA 2015. A quinta seção apresenta os resultados para o decaimento e uma discussão sobre os fatores associados ao declínio de desempenho e a particularidade do caso brasileiro. Já a sexta seção apresenta as estimações para a descontinuidade e replica metodologias de outros trabalhos para validar a medida de recuperação. Concluímos na sétima seção e apresentamos os desenvolvimentos futuros propostos.

2. Revisão da Literatura

Esse artigo se relaciona com duas linhas principais da literatura. Em primeiro lugar, nosso artigo contribui com os estudos que investigam medidas de habilidades cognitivas e não cognitivas. Alguns trabalhos que relacionam habilidades cognitivas com crescimento econômico constroem medidas daquelas habilidades utilizando notas de avaliações internacionais (Hanushek & Kimko, 2000; Hanushek & Woessmann, 2012). Há, no entanto, um ramo da literatura que verifica a influência de traços de personalidade e motivação sobre o resultado de testes de inteligência (Duckworth et al., 2009; Segal, 2012; Borghans et al., 2008), e a influência do contexto e dos incentivos envolvidos nesses testes (Almund et al., 2011), apesar de alguns estudos não encontrarem uma relação clara entre estas duas variáveis (Eklöf, 2007).

Mais recentemente, Akyol, Krishna, e Wang (2018) decompõem o papel da motivação no desempenho em testes com baixas expectativas. Eles usam o PISA 2015 para identificar alunos que fazem a prova de maneira "não séria", segundo critérios de tempo e padrões de resposta, sendo que 25% dos alunos de todos os países faz a prova dessa maneira. Para o Brasil, 67% dos alunos podem ser considerados "não sérios". No entanto, da mesma forma que neste trabalho, ao considerar todos os alunos fazendo a prova de forma séria o Brasil não ganha muitas posições no ranking de probabilidade de acertar as questões na prova, devido ao baixo conhecimento dos alunos "não sérios".

Em segundo lugar, nosso artigo se relaciona com a literatura psicométrica que foca no contexto do exame e em suas características, como o posicionamento dos itens. Davis e Ferdous (2005), constatam que a literatura tende a associar o crescimento da dificuldade dos itens como um possível efeito de "fadiga", quando o desempenho diminui e a dificuldade do item, portanto, aumenta, enquanto os alunos avaliados passam a decair em aspectos relacionadas ao desempenho, como motivação, concentração e nível de energia. Albano (2013) verifica que há viés em estimações pela Teoria de Resposta ao Item (TRI) de exames que mantêm a mesma posição das questões para todos as provas, uma vez que existe um grau diferenciado de dificuldade associado a cada item de acordo com sua posição e não exclusivamente ao seu conteúdo.

Além disso, há dois trabalhos dessa literatura que se relacionam mais diretamente com nosso artigo. Borghans e Schils (2012) buscam identificar a influência das habilidades socioemocionais no decorrer de um exame com baixa expectativa. Os principais resultados apresentados demostram uma grande queda do desempenho dos alunos

durante as provas, porém essa queda não está correlacionada com o resultado final da prova. Além disso, a medida de habilidades socioemocionais a partir do decaimento nas provas é correlacionada com a medida auto reportada e esses indicadores são bons preditores de resultados como renda e hábitos de saúde no futuro.

Marchioni (2017) se utiliza da metodologia de Borghans e Schils (2012) e os dados do PISA de 2012 para avaliar as habilidades cognitivas e não-cognitivas dos países latino-americanos em comparação com os outros países que participam do exame, assim como para avaliar diferenças entre gênero e entre escolas públicas e privadas. Os principais resultados deste trabalho sugerem que os países latino-americanos, em geral, têm níveis menores de habilidades cognitivas e não-cognitivas em relação ao outros grupos de países do exame, que o gênero feminino está melhor no que tange às habilidades não-cognitivas e que não foram encontradas, entre países, diferenças gerais significativas entre os alunos de escolas pública e de escolas privada. No entanto, para certos países essa diferença é significativa. É possível que os padrões de segregação socioeconômica por tipo de escola sejam o que orienta a diversidade de resultados encontrados, considerando o tipo de escola como uma *proxy* para o status socioeconômico de um aluno. O resultado é intuitivo nos casos em que o decaimento é menor para aos alunos da escola particular, já que se pode pensar que o status socioeconômico da família é um importante fator na formação de habilidades não-cognitivas.

3. Descrição do PISA 2015

Utilizaremos os microdados do PISA 2015. O PISA é uma avaliação educacional realizada em nível internacional com o objetivo de avaliar o sistema educacional dos países participantes. O exame é feito a cada três anos por uma amostra de alunos com entre 15 anos e 2 meses e 16 anos e 3 meses de idade, matriculados em alguma instituição educacional. Em 2015, participaram 70 países, sendo 35 deles participantes da Organização para Cooperação e Desenvolvimento Econômico (OCDE) e ou demais 35, países parceiros. No Brasil, o exame abrangeu 23.141 estudantes de 841 escolas.

O exame consiste em questões de ciências, literatura e matemática ou de resolução colaborativa de problemas, durante duas horas. Os alunos não fazem todos as mesmas provas e nem as mesmas questões. Cada aluno recebe uma combinação aleatória de questões, alternando as matérias e ordem de aparecimento de cada questão entre os alunos. Os alunos também não fazem provas de todas as matérias. O exame é estruturado de forma que há uma variedade de conjuntos de questões (chamados de *clusters*) de cada uma das matérias e a cada aluno são designados apenas quatro dos *clusters* possíveis. Há inúmeras combinações de *clusters*, essas combinações são identificadas por um número e dão origem a um formulário de prova, cada formulário é composto por quatro desses *clusters*. O formulário de prova que um aluno recebe é aleatório.

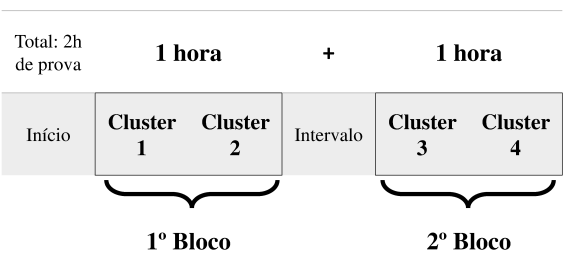
Para o ano de 2015, havia 30 formulários de provas do tipo PBA (*Paper-Based Assessment*) e 396 formulários de prova do tipo CBA (*Computer-Based Assessment*) no desenho geral do exame. Dos 70 países que participaram do PISA 2015, apenas 15 países receberam provas exclusivamente do tipo PBA, e nenhum dos países recebeu

simultaneamente provas do tipo CBA e PBA. O Brasil foi um dos países que, conforme a maioria, aplicou somente as provas do tipo CBA.

A documentação do PISA apresenta quais são e em que posição estão os *clusters* em cada um dos formulários de prova, assim como o livro de códigos das questões apresenta o ordenamento delas dentro de cada um dos *clusters* (OCDE, s. d.).

Como vimos, o formulário de prova que um aluno recebe é aleatório.[1] A Figura 1 ilustra o formato das provas que os alunos recebem. Devido a essa montagem do exame, a posição de cada uma das questões é aleatória e configura uma fonte de variação exógena. A intenção dos organizadores do PISA é de que os *clusters* possuam nível níveis de dificuldade homogêneos entre si e o tempo esperado para a resolução de cada um deles é de 30 minutos. Dessa forma, o exame tem o tempo máximo de duas horas, sendo dividido em dois blocos de uma hora cada e separados por uma pequena pausa entre os dois blocos, em geral de 5 minutos.[2] O exame de conhecimentos acaba no segundo bloco. Após os dois blocos de provas, os alunos respondem a questionários não avaliativos referentes aos seus dados socioeconômicos, familiares e a perguntas relacionadas ao funcionamento das escolas, atividades pedagógicas e sobre suas opiniões quanto ao estudo das matérias que são avaliadas no PISA.

A Tabela 1 mostra os testes de aleatorização da ordem das questões para características individuais e socioeconômicas, sendo essas: gênero, série que frequenta, mês de nascimento, possuir uma mesa de estudos em casa, possuir um quarto individual, possuir um lugar específico para estudar em casa, possuir um computador para estudar, o maior grau de escolaridade dos pais e possuir uma quantidade mínima de livros em casa. Para esses testes, regredimos as *dummies* de cada característica nas *dummies* dos códigos das provas e suas interações, e reportamos as estatísticas F de significância conjunta do modelo, assim como os p-valores associados. Os resultados mostram que não podemos rejeitar a hipótese nula de que os coeficientes são conjuntamente iguais a zero, ou seja, não há uma associação clara entre os códigos de provas e as características individuais. Dessa forma, temos maior confiança de que podemos considerar a alocação de cada questão como aleatória para cada estudante.



Fonte: Documentação do PISA 2015. Elaboração própria.

Figura 1. Formato da Prova do PISA 2015.

[1] A Tabela 1 mostra os resultados para regressões de variáveis *dummy* para cada um dos grupos de alunos que responderam a cada combinação de CBA nas características individuais dos alunos.

[2] Não há uma regra fixa para a duração do intervalo. No geral, ele é de 5 minutos, porém no Brasil, chega a aproximadamente 15 minutos.

Tabela 1. Teste de Aleatorização

	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)
Variável Dependente	Gênero	Série	Mês de Nasc.	Mesa	Quarto	Lugar de estudos	Computador	Escolaridade Pai	Escolaridade Mãe	Livros
F-Stat[a]	1,025	1,034	0,884	1,057	1,058	1,020	0,869	0,907	1,112	0,969
P-val	0,355	0,309	0,952	0,210	0,207	0,381	0,971	0,905	0,0639	0,663
DF 1	395	395	395	395	395	395	395	395	395	395
DF 2	22.745	22.745	22.745	20.638	19.859	20.195	20.290	19.882	20.631	20.875
R^2	0,017	0,018	0,015	0,020	0,021	0,020	0,017	0,018	0,021	0,018
Obs.	23.141	23.141	23.141	21.034	20.255	20.591	20.686	20.278	21.027	21.271

Notas: Regressões de *dummies* de Bookid, Science Cluster Random Number e suas respectivas interações nas características individuais. Os coeficientes de cada *dummy* não são apresentados nos resultados. Por suposição, todos os coeficientes estimados associados a cada grupo devem ser iguais a zero. DF = Graus de Liberdade, tal que F-Stat $\sim F(DF1, DF2)$. [a] F-Stat é a estatística do teste F para a hipótese de que todos os parâmetros de *Booklet*, *Random Science Cluster Number* e suas interações são conjuntamente iguais a zero.

4. Estratégia empírica de decomposição do desempenho

Nessa seção descrevermos o procedimento de estimação do decaimento dos alunos ao longo da prova formulado em Borghans e Schils (2012), e também utilizado em Marchioni (2017) e Balart et al. (2018). Nós também proporemos um segundo procedimento, para estimar uma medida alternativa ao decaimento, que chamaremos de recuperação durante a prova. A medida de decaimento consiste em estimar a diferença entre a probabilidade de acerto na primeira questão e a probabilidade de acerto na última questão. Já a medida de recuperação explora a descontinuidade da probabilidade de acerto das questões no entorno do intervalo das provas, sendo elaborada a partir de um modelo polinomial com um desenho de RDD (*Regression Discontinuity Design*), tendo a distância ao intervalo como referência para o modelo. Em geral, os alunos apresentam uma probabilidade de acerto muito baixa pouco antes do intervalo e uma alta probabilidade de acerto após o intervalo, semelhante à probabilidade de acerto no início da prova.

Uma inovação metodológica proposta por este trabalho é levar em conta, mesmo para a estimação do decaimento, a influência do intervalo entre as provas. Obtendo a resultados mais acurados para a probabilidade de acerto no início e no final da prova. Tanto o decaimento como a recuperação são apresentados como uma tentativa de capturar a influência das habilidades não cognitivas durante uma prova.

Para dar mais clareza aos efeitos estimados, a Figura 2 demostra uma interpretação gráfica das duas medidas de habilidades não cognitivas que podem ser construídas, nela temos a probabilidade média de acerto no eixo das ordenadas e a posição das questões, variando de 0 a 1, no eixo das abscissas e trajetória da probabilidade de acerto representada em linhas sólidas. O ponto inicial representa a probabilidade de acertar a primeira questão, que pode ser considerada uma medida de habilidades cognitivas. O ponto final do gráfico representa o probabilidade de acerto da última questão da prova. O decaimento é a medida dessa diferença (Efeito A). Já a recuperação é representada pelo Efeito B, estimado a partir da descontinuidade da probabilidade de acerto no ponto mediano da prova.

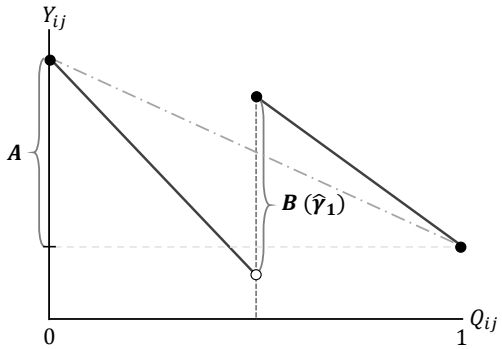


Figura 2. Ilustração de resultados dos modelos.

O motivo da queda de desempenho ao longo do exame pode ser devido a vários fatores, mas a medida de decaimento em si, apesar de representar a influência das habilidades não cognitivas, é linearmente dependente da probabilidade de acerto da primeira questão, ou seja, das habilidades cognitivas. Ao consideramos a descontinuidade de desempenho ao redor do intervalo, propomos uma outra medida que seja, ao menos, linearmente independente do ponto inicial, portanto, capaz de representar melhor fatores não cognitivos.

Borghans e Schils (2012) desenvolve uma abordagem para se decompor as notas do PISA em dois elementos: o desempenho inicial e o decaimento no desempenho durante o teste. Para estimar o decaimento de desempenho consideramos que a probabilidade de acertar uma questão durante um exame depende da habilidade cognitiva dos alunos, assim como depende também de suas habilidades socioemocionais. Outro fator que influencia essa probabilidade são as condições e o contexto em que cada questão é apresentada. Pelas características intrínsecas a cada um desses fatores, há grande dificuldade em discernir os seus efeitos separadamente, e qualquer estratégia de identificação possível depende de hipóteses sobre o tipo de influência de cada um desses sobre a probabilidade de acertar uma questão.

Utilizamos a posição relativa de cada questão no exame a fim de identificar o efeito das habilidades socioemocionais ou não cognitivas. Para isso, nos valemos da hipótese de que as mesmas não influem na probabilidade de acertar uma questão logo no início da prova, i.e., no início de uma prova apenas a habilidade cognitiva influencia a probabilidade de acertar a questão. Ao longo da prova, no entanto, traços da personalidade como atenção, motivação ou persistência passam a ter maior relevância na probabilidade de acerto das questões. Para que as estimativas desse efeito não sejam enviesadas, é preciso que a posição de cada questão seja não correlacionada com outras características que influenciem em sua dificuldade, como seu conteúdo e disciplina. Também é necessário que a posição de cada questão seja não correlacionada com a habilidade cognitiva ou com caraterísticas individuais (posses individuais, contexto familiar, educação dos pais, etc.) que podem influenciar nas habilidades cognitivas de cada aluno realizando os exames. Essas duas últimas condições são garantidas pela aleatorização dos *clusters* de questões, confirmada nos resultados da Tabela 1.

A estratégia empírica aqui adotada para identificar o decaimento é a mesma adotada em Borghans e Schils (2012), Marchioni (2017) e em Balart et al. (2018), mas

incluindo também uma variável para capturar o efeito do pequeno intervalo entre as duas horas de prova. Para tanto, estimamos o seguinte modelo:

$$Z_{ij} = \beta_0 + \beta_1 I_1 Q_{ij} + \beta_2 Q_{ij} + \beta_3 I_1 + \sum_{j=2}^{J} \mu_j + \varepsilon_{ij}, \tag{1}$$

onde a variável dependente Z_{ij} é a *dummy* de acerto da questão j pelo indivíduo i. Como variáveis explicativas temos: Q_{ij} é a posição normalizada entre 0 e 1 da questão, sendo que para a primeira questão o valor atribuído a Q_{ij} é 0, para a última questão antes do intervalo o valor é de 0,5 e para última questão, é igual 1; I_1 é uma variável dummy para as questões após o intervalo; o termo μ_j é o efeito fixo de cada uma das questões, sua utilização se dá pela intenção de se controlar pela dificuldade específica de cada uma das questões. Com a especificação linear incluindo a variável para capturar o efeito do intervalo, a interpretação não é direta, o decaimento é obtido a partir da equação (2), com a diferença entre a probabilidade de acertar a primeira e últimas questões:

$$\begin{aligned} Decaimento &= \widehat{Z_1} - \widehat{Z_0}\,, \\ Decaimento &= \widehat{\beta_1} + \widehat{\beta_2} + \widehat{\beta_3}\,. \end{aligned} \tag{2}$$

Como mencionado acima, estimaremos também uma medida de recuperação da probabilidade de acertos entre o intervalo, nos valendo das mesmas características de aleatorização para estimar o decaimento. Notamos que há dois momentos distintos em que o aluno perde a capacidade de acerto das questões, durante o primeiro bloco de provas e durante o segundo bloco de provas.

Podemos supor que os alunos já muito prejudicados por fatores que atrapalham o seu desempenho ideal no final da primeira prova, ao serem expostos a uma pequena pausa, reiniciam a prova no segundo bloco mais concentrados, motivados ou ainda capazes de ler e interpretar melhor as questões pela experiência prévia na parte anterior. Começando o segundo bloco de questões quase tão bem dispostos quanto no início do primeiro bloco.

Desta forma, alunos que não são prejudicados por estes fatores não cognitivos não deveriam apresentar recuperação nenhuma, uma vez que o seu desempenho é resultado somente de suas habilidades cognitivas. Já alunos muito prejudicados no primeiro bloco devem apresentar uma grande recuperação entre os dois blocos, uma vez que quase toda a sua capacidade de responder as questões é afetada por fatores não cognitivos. Assim, a medida aqui proposta não é inteiramente substituta ou mesmo independente do decaimento, mas apenas se distancia dos extremos da prova para capturar a influência das habilidades socioemocionais.

Para estimarmos com maior precisão a descontinuidade do desempenho dos alunos no intervalo, apresentamos os resultados de uma forma polinomial cúbica da equação (1), apresentada na equação (3). Seguiremos a estrutura e o desenho de uma regressão descontínua, de modo a atenuar um possível viés gerado pela estimação de coeficientes lineares de uma variável continua em torno da descontinuidade:

$$Z_{ij} = \gamma_0 + \gamma_1 I_1 + \gamma_2 I_1 X_{ij} + \gamma_3 X_{ij} + \gamma_4 I_1 X_{ij}^2 + \gamma_5 X_{ij}^2 + \gamma_6 I_1 X_{ij}^3 + \gamma_7 X_{ij}^3 + \sum_{j=2}^{J} \mu_j + \varepsilon_{ij}\,. \tag{3}$$

Nesta equação, X_{ij} é uma variável derivada da posição normalizada Q_{ij}, que mede a distância relativa de cada ponto da prova ao intervalo, variando de 0,5 a 0,5. A construção da variável deste modo faz com que todas as questões anteriores ao intervalo respondam por 50% da prova e todas as questões após o intervalo respondam pelos outros 50% de prova. Neste modelo, o coeficiente de interesse é γ_1, associado à variável *dummy* que denota as questões após o intervalo (I_1), e exprime a dimensão da descontinuidade em relação à variável dependente do modelo. Ao utilizarmos um modelo de probabilidade linear, essa dimensão está limita entre 0 e 1. Desta forma, a descontinuidade estimada para cada país será expressa pelo coeficiente $\hat{\gamma}_1$ e interpretada como a recuperação, entre os dois blocos de prova, da capacidade de acerto das questões.

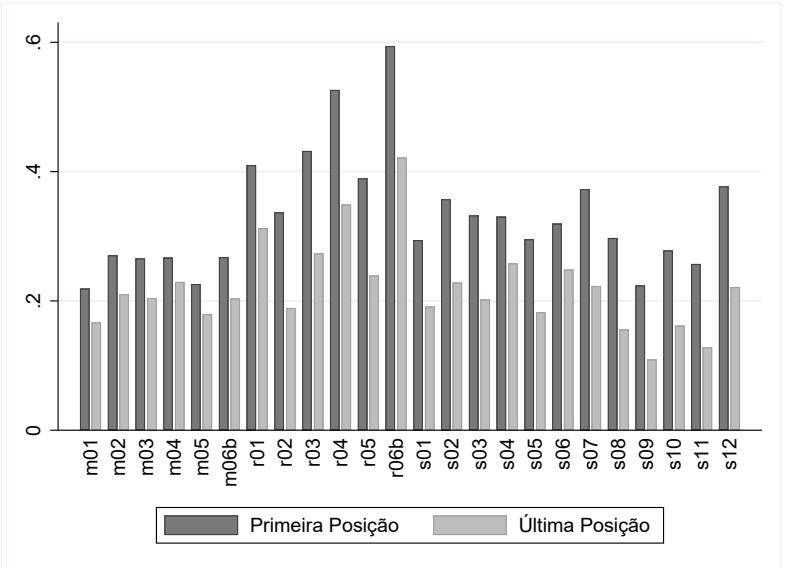
5. Decaimento

Em primeiro lugar, verificamos que há decaimento do desempenho dos alunos. Como podemos ver na Figura 3, há declínio no desempenho mesmo se comparamos os acertos médio nos próprios *clusters* de questões, quando aparecem na primeira ou última posição da prova. A Figura 4 mostra que mesmo se dividirmos as provas por disciplina, o padrão de queda do desempenho se mantém. Adicionalmente, para alguns *clusters* há um comportamento a princípio não esperado, pois quando apresentados na terceira posição há uma maior probabilidade de acerto do que quando apresentados na segunda, mas ainda assim a probabilidade é menor do que quando apresentados na primeira posição. Isso se deve, novamente, ao fato de que, foi imposta aos participantes do exame uma pequena pausa de no máximo 5 minutos antes de começar o bloco de testes dos *clusters* três e quatro, e o tempo de resolução para cada grupo de dois *clusters* foi limitado a apenas uma hora. Uma particularidade do exame em 2015 é de que os participantes que realizaram os testes em computadores (provas do tipo CBA) tiveram de resolver as questões do teste de uma forma fixa e sequencial, de modo que não podiam voltar para perguntas anteriores e revisar suas respostas depois de chegar ao final de cada teste. Mesmo assim, para nenhum *cluster* há probabilidade maior de acertar as questões em qualquer outra posição que não a primeira. Isso é um indício que de fato há influência das habilidades socioemocionais no decorrer da prova.

5.1 Estimativas de decaimento

A Tabela 2 mostra que a queda de desempenho estimado ao longo de uma prova extensa como o PISA difere significativamente entre países, assim como difere a probabilidade média dos alunos de cada país acertarem a primeira questão de uma mesma prova. O Brasil aparece com um dos menores níveis de probabilidade de acertar a primeira questão, o que pode indicar um baixo nível de habilidades cognitivas (posição 48 de 56).[3] O decaimento brasileiro é o maior, o que representa, na interpretação de Borghans e Schils (2012), um baixo nível de habilidades socioemocionais. Podemos notar uma correlação negativa entre as duas medidas, o que significa que os países que mais acertam a primeira questão são também aqueles que tem menor decaimento.

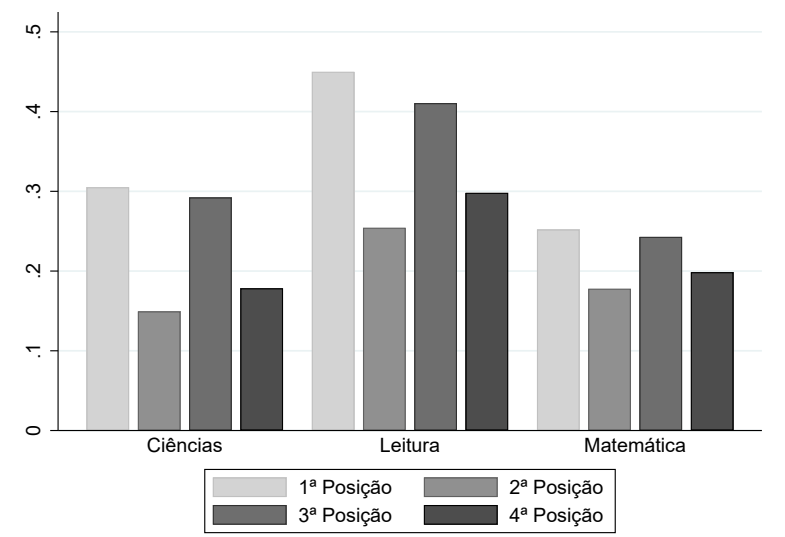
[3]Consideramos 56 regiões e países que fizeram a prova em CBA, excluindo regiões específicas dos EUA que fazem a prova de modo separado, excluindo também o território de Porto Rico, que não fez a prova em formato CBA.



Nota: Percentual de acertos utilizando a amostra de todos os países. Para cada cluster, a letra inicial indica sua disciplina ("m" para matemática, "r" para leitura e "s" para ciências).

Fonte: PISA 2015. Elaboração própria.

Figura 3. Percentual de Acertos Dentro dos *clusters*, por Posição na Prova.



Nota: Percentual de acertos utilizando a amostra de todos os países.

Fonte: PISA 2015. Elaboração própria.

Figura 4. Percentual Médio de Acertos em cada Disciplina por Posição na Prova.

Tabela 2. Queda de desempenho estimada para países que fizeram a prova em CBA.

País	Prob. Acertar a 1ª Questão	Prob. Acertar última antes do Break[a]	Prob. Acertar a 1ª após o Break[b]	Prob. Acertar a Ultima Questão	Decaimento (Total)	Decaimento Antes do Break[c]	Decaimento Após o Break[b]
Brazil	0,403	0,130	0,360	0,176	0,227	0,273	0,184
Uruguay	0,453	0,267	0,411	0,287	0,167	0,186	0,125
Tunisia	0,340	0,168	0,283	0,179	0,161	0,172	0,104
Russian Federation	0,541	0,369	0,508	0,383	0,158	0,172	0,125
Portugal	0,577	0,395	0,529	0,428	0,149	0,182	0,102
Sweden	0,564	0,402	0,523	0,420	0,143	0,162	0,102
Mexico	0,411	0,223	0,373	0,270	0,141	0,189	0,104
Peru	0,370	0,165	0,339	0,231	0,139	0,205	0,108
Colombia	0,413	0,243	0,371	0,276	0,137	0,170	0,095
Montenegro	0,397	0,269	0,360	0,261	0,136	0,128	0,099
Slovak Republic	0,503	0,383	0,459	0,369	0,134	0,120	0,090
New Zealand	0,581	0,446	0,545	0,449	0,132	0,135	0,096
Thailand	0,401	0,270	0,360	0,277	0,124	0,131	0,083
Italy	0,535	0,416	0,497	0,413	0,123	0,119	0,085
Israel	0,501	0,366	0,459	0,381	0,121	0,135	0,078
France	0,555	0,440	0,517	0,435	0,121	0,115	0,083
Norway	0,571	0,456	0,530	0,450	0,120	0,115	0,080
Bulgaria	0,463	0,318	0,427	0,348	0,115	0,146	0,079
Costa Rica	0,400	0,265	0,371	0,285	0,115	0,134	0,086
Chile	0,457	0,326	0,423	0,344	0,113	0,131	0,079
Greece	0,482	0,358	0,446	0,370	0,113	0,124	0,077
Luxembourg	0,527	0,405	0,489	0,417	0,111	0,122	0,072
Australia	0,563	0,472	0,534	0,455	0,108	0,091	0,080
Hungary	0,501	0,420	0,475	0,394	0,107	0,081	0,081
United Arab Emirates	0,436	0,353	0,395	0,331	0,105	0,083	0,064
Belgium	0,564	0,465	0,535	0,461	0,103	0,099	0,074
Spain	0,543	0,426	0,512	0,441	0,102	0,117	0,071
Spain (Regions)	0,546	0,434	0,513	0,445	0,101	0,112	0,068
Switzerland	0,571	0,468	0,535	0,470	0,101	0,103	0,066
Iceland	0,506	0,411	0,469	0,405	0,101	0,096	0,064
Dominican Republic	0,266	0,125	0,247	0,167	0,100	0,142	0,080
Qatar	0,369	0,267	0,334	0,274	0,095	0,102	0,060
United States	0,538	0,435	0,504	0,446	0,092	0,103	0,058
Austria	0,535	0,477	0,503	0,445	0,091	0,058	0,058
Slovenia	0,568	0,523	0,523	0,479	0,089	0,044	0,044
Japan	0,602	0,526	0,598	0,522	0,080	0,076	0,076
Czech Republic	0,536	0,456	0,514	0,456	0,080	0,080	0,057
Denmark	0,563	0,474	0,535	0,483	0,079	0,089	0,052
Latvia	0,512	0,452	0,493	0,433	0,079	0,060	0,060
United Kingdom	0,555	0,503	0,529	0,477	0,078	0,052	0,052
Canada	0,596	0,521	0,566	0,520	0,076	0,075	0,046
Turkey	0,399	0,341	0,382	0,324	0,075	0,058	0,058
Germany	0,564	0,488	0,550	0,496	0,068	0,076	0,054
Estonia	0,596	0,533	0,582	0,532	0,065	0,064	0,050
Lithuania	0,488	0,433	0,478	0,424	0,064	0,054	0,054
B-S-J-G (China)	0,571	0,493	0,572	0,510	0,061	0,078	0,063
Macao	0,591	0,495	0,577	0,536	0,055	0,095	0,042
Netherlands	0,569	0,530	0,554	0,515	0,054	0,039	0,039
Poland	0,540	0,486	0,546	0,492	0,048	0,054	0,054
Finland	0,581	0,538	0,582	0,539	0,043	0,043	0,043
Singapore	0,635	0,589	0,622	0,592	0,043	0,046	0,030
Hong Kong	0,597	0,558	0,595	0,557	0,040	0,038	0,038
Croatia	0,474	0,435	0,483	0,445	0,029	0,039	0,039
Korea	0,559	0,537	0,554	0,533	0,026	0,021	0,021
Ireland	0,539	0,507	0,546	0,515	0,024	0,031	0,031
Chinese Taipei	0,576	0,562	0,579	0,566	0,010	0,013	0,013

Nota: Decaimento estimado conforme a equação (1) e probabilidade de acertar a primeira questão, para cada sessão da prova, levando em conta o intervalo e os pesos amostrais do PISA 2015. Todas as estimativas são significativas ao menos a 5%.

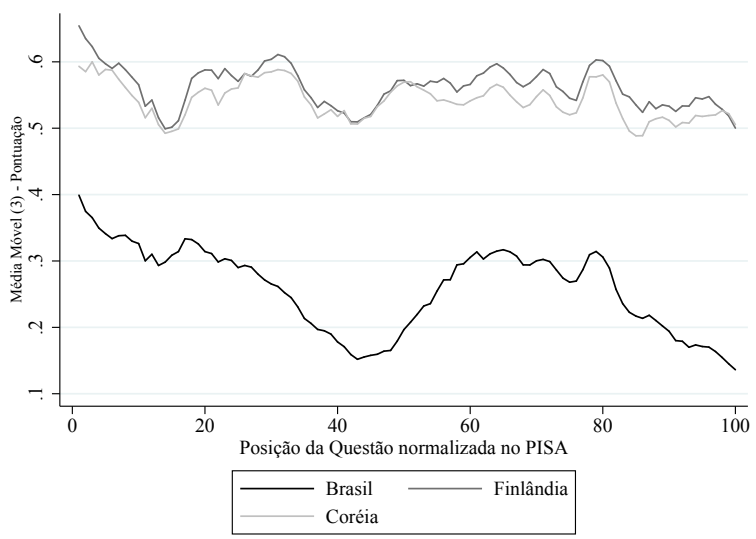
Fonte: PISA 2015. Elaboração própria.

Ainda nesta tabela, temos as probabilidades de acertos estimadas em pontos específicos da prova, como a última questão antes do intervalo (break) e a primeira questão após o intervalo, nota-se uma diferença razoável entre estas duas estimativas, sugerindo que a validade de alguma recuperação envolvendo o intervalo entre os blocos de prova. Mesmo com alguma recuperação providenciada pelo intervalo, a probabilidade de acerto da primeira questão após o intervalo dos alunos brasileiros é ainda menor em comparação aos outros países (posição 52 de 56).

Ilustramos o decaimento dos alunos brasileiros ao longo da prova, em comparação com países com bom desempenho na Figura 5, onde comparamos a probabilidade de acertos de alunos do Brasil, Finlândia e Coréia do Sul ao longo da prova. Podemos notar que, à medida em que os alunos avançam para o final da prova, onde a posição normalizada da questão é igual a 1, a queda na taxa de acertos é muito mais acentuada para o Brasil do que para Finlândia e Coréia do Sul. O desempenho ao longo da prova destes últimos parece ser mais constante e menos afetado por fatores que não podem ser atribuídos ao "conhecimento" dos alunos, como o tempo total de prova ou o cansaço e a distração decorrente de uma prova mais longa.

5.2 Possíveis explicações para o decaimento

Por que o Brasil possui um decaimento tão grande em relação ao dos demais países? Isso se deve somente às habilidades socioemocionais, ou também há outros fatores envolvidos? Nessa seção, exploramos com mais detalhes a estrutura do exame e as variáveis de tempo de cada item, para tentar responder a essas questões. Na edição de 2015, os exames do tipo CBA tinham a limitação de uma estrutura sequencial das



Nota: Médias móveis de 3 termos defasados da probabilidade de acertos observados ao longo da prova para Brasil, Finlândia e Coréia do Sul, por posição normalizada da questão. O eixo horizontal mostra a posição normalizada das questões, colocando o intervalo na posição 0,5 e o final da prova na posição 1.

Fonte: PISA 2015. Elaboração própria.

Figura 5. Queda de desempenho observada ao longo da prova para o Brasil, Finlândia e Coréia do Sul.

questões, com tempo fixo por bloco de prova. Essas características evidenciam alguns pontos que nos ajudam a entender o desempenho do Brasil.

A Tabela A-1, no Apêndice, mostra a proporção de acertos, a proporção daqueles que não chegaram ao item e tempo médio em cada questão, ao longo da prova. Em primeiro lugar, como o esperado, a taxa de acertos decai ao longo da prova e dentro de cada bloco de dois *clusters*. Como também é esperado, a proporção daqueles que não chegam nem a responder à questão é crescente em cada bloco. No entanto, o aumento da proporção é muito acelerado e chega ao máximo de 60%. Esse padrão sugere que os alunos brasileiros não conseguem administrar bem o tempo de prova e que a pontuação dos alunos brasileiros poderia ser maior, caso estes conseguissem completar os blocos de questões.[4]

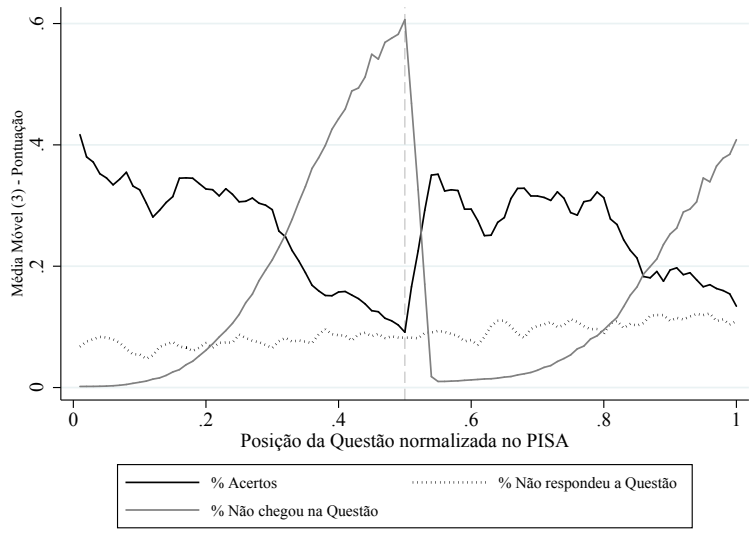
Em segundo lugar, a Figura 6, que mostra apenas estas estatísticas para o Brasil, deixa clara a diferença entre os dois blocos. A proporção dos alunos que não chegam à questão é claramente menor no segundo bloco, especialmente no final do bloco, em que chega a 40%, em comparação ao pico da primeira parte. Além disso, no segundo bloco, a taxa de acertos parte de um nível menor e chega a um nível maior do que no primeiro bloco, sendo menos decrescente e relativamente mais estável. Essas diferenças sugerem que os alunos brasileiros aprendem a fazer a prova entre os dois blocos, distribuindo melhor o tempo de resolução das questões.

Na Figura 7, comparamos a participação dos alunos em cada posição das questões na prova com a de outros países. Notamos que a porcentagem de questões não alcançadas pelos alunos brasileiros é muito maior em relação à mesma para países exemplares no PISA, como a Finlândia, ou mesmo para a Colômbia, cujo desempenho no PISA é comparável ao desempenho brasileiro. Enquanto a última questão do primeiro bloco de uma hora não é alcançada por, aproximadamente, 6% dos alunos finlandeses e 18% dos alunos colombianos, cerca de 61% dos alunos brasileiros não alcançam essa mesma questão.

Os dados de aplicação das provas do tipo CBA no PISA 2015 apresentam também o tempo que os alunos levaram para responder cada questão de seus respectivos formulários de prova. Na Figura 8, reportamos o tempo médio de resposta ao longo da prova. A figura mostra que os alunos brasileiros gastam muito tempo para responder às questões iniciais da prova, fazendo com que poucos consigam chegar ao final das provas. É possível que os alunos que não chegam ao final da prova levem mais tempo para ler e entender o enunciado das questões e elaborar o raciocínio que leva à resposta. Nesse sentido, o mal desempenho dos alunos teria pouco a ver com habilidades socioemocionais e dependeriam mais das habilidades cognitivas.

Ao compararmos o tempo médio de resolução das questões ao longo da prova de outros países com o tempo médio dos alunos brasileiros, na Figura 9, podemos notar que este é muito menor para países exemplares no PISA, como Coréia do Sul e Finlândia, e com variância menor. Curiosamente, ao compararmos os resultados

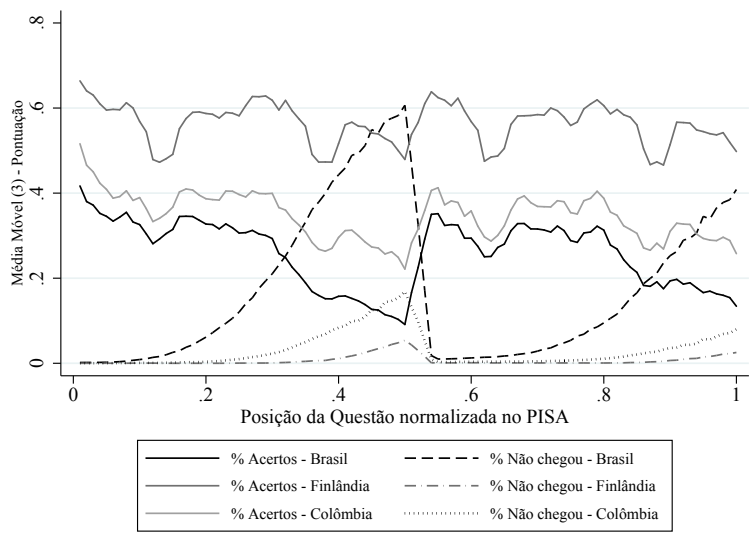
[4]Mais especificamente, o desempenho seria melhorado, caso o efeito marginal de cada unidade de tempo sobre a probabilidade de acerto do item fosse maior no final da prova (para uma questão adicional) do que no início da prova (para questões que já estão sendo resolvidas). Esse aspecto está associado à organização da prova, uma vez que, ao contrário das provas do tipo PBA, os alunos não podem escolher as questões que sabem responder e reflete mais a estratégia de resolução da prova, do que o conhecimento sobre os assuntos.



Nota: Proporção de acertos, de não respostas e de casos em que o aluno não chega na questão, por posição normalizada da questão. Os três percentuais somados, mais a proporção de respostas erradas, totaliza 100%. O eixo horizontal mostra a posição normalizada das questões, colocando o intervalo na posição 0,5 e o final da prova na posição 1.

Fonte: PISA 2015. Elaboração própria.

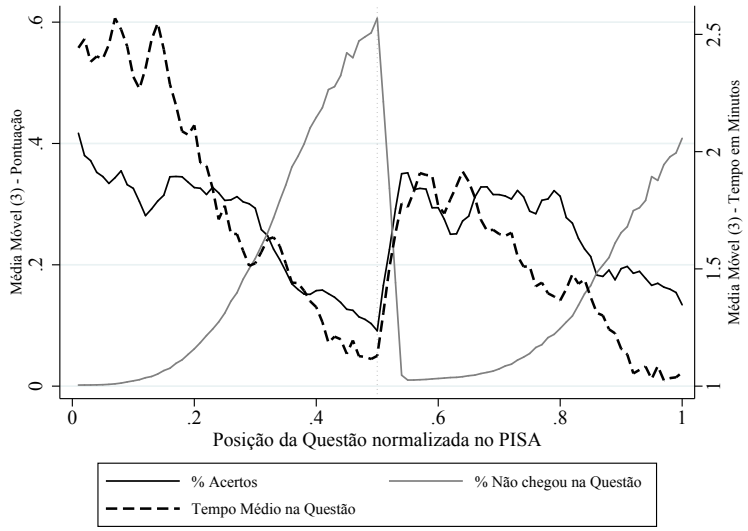
Figura 6. Queda de desempenho observada e porcentagem de alunos brasileiros que não respondeu às questões no PISA 2015.



Nota: Proporção de acertos e de casos em que o aluno não chega na questão, por posição normalizada da questão. Os dois percentuais somados, mais a proporção de respostas erradas e de não resposta, totaliza 100%. O eixo horizontal mostra a posição normalizada das questões, colocando o intervalo na posição 0,5 e o final da prova na posição 1.

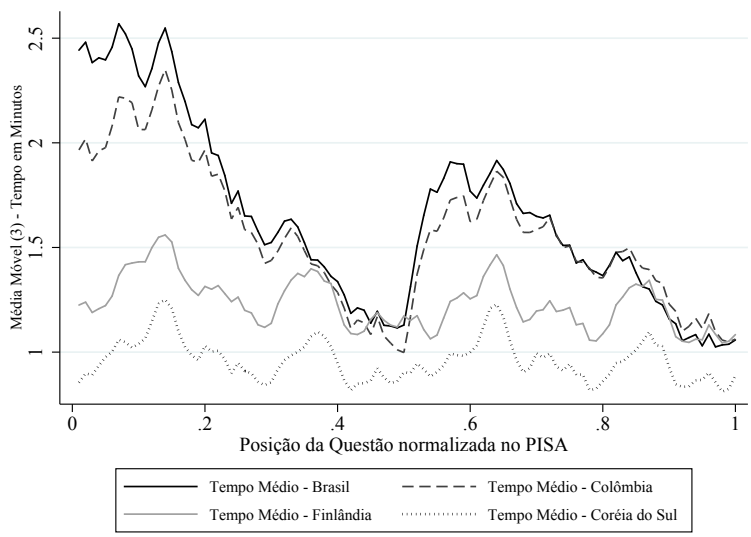
Fonte: PISA 2015. Elaboração própria.

Figura 7. Queda de desempenho e porcentagem de alunos que não chegaram às questões, Brasil em comparação a outros países no PISA 2015.



Nota: Proporção de acertos, de casos em que o aluno não chega na questão e tempo médio gasto na questão, por posição normalizada da questão. Os dois percentuais somados, mais a proporção de respostas erradas e de não resposta, totaliza 100%. O eixo horizontal mostra a posição normalizada das questões, colocando o intervalo na posição 0,5 e o final da prova na posição 1.
Fonte: PISA 2015. Elaboração própria.

Figura 8. Queda de desempenho, porcentagem de alunos brasileiros que não conseguiu responder e tempo médio gasto nas questões no PISA 2015.



Nota: Tempo médio gasto na questão, por posição normalizada da questão. O eixo horizontal mostra a posição normalizada das questões, colocando o intervalo na posição 0,5 e o final da prova na posição 1.
Fonte: PISA 2015. Elaboração própria.

Figura 9. Tempo médio gasto nas questões, Brasil em comparação a outros países no PISA 2015.

colombianos com os resultados brasileiros, vemos que, mesmo com um tempo médio pouco menor do que o tempo médio brasileiro, a parcela dos alunos colombianos que chega ao final das provas é consideravelmente maior do que a parcela de alunos brasileiros (Figura 7).

A redução do tempo médio ao longo de um bloco pode refletir dois movimentos. O primeiro deles, é um efeito composição, em que aqueles que gastam mais tempo nas primeiras questões acabam não chegando às questões ao final do bloco, de modo que aqueles que respondem a essas questões (e que entram na conta da média) são os alunos que já tinham tempo menor de resposta. O segundo efeito é de aprendizado, ou de estratégia de resolução da prova, em que o mesmo aluno pode reduzir o tempo de resolução da cada questão para tentar responder mais questões. A diferença entre o Brasil e a Colômbia pode ser explicada por um ou outro desses fatores ter maior peso. Enquanto na Colômbia o segundo efeito parece ser mais acentuado, no Brasil o efeito composição parece ser maior, de modo que os alunos que gastam mais tempo nas primeiras questões não passam a controlar o tempo de resposta por questão para chegar mais longe na prova.

A Tabela 3 descreve a influência do tempo médio gasto nos primeiros 5% de questões após o início de cada bloco de uma hora de provas. Vemos que, para os países com desempenho relativamente constante ao longo da prova (Finlândia e Coréia do Sul), a média de tempo por questão é menor e os tempos máximos dos quatro grupo de alunos são mais concentrados em torno desta média. Além disso, os alunos que tomam mais tempo nas primeiras questões de fato tem menor probabilidade de chegar ao final de cada bloco do exame, porém apresentam uma probabilidade de acertar maior do que a de seus pares que demoram menos tempo. Já para o Brasil e a Colômbia, vemos que o tempo médio por questão é maior, e os valores máximos dos grupo de alunos são mais dispersos. Além disso, apesar das médias de tempo suficientemente parecidas, há grandes diferenças em relação à probabilidade de chegar ao final do bloco. Entre os alunos brasileiros do grupo com menor tempo de resolução das questões, apenas 54% conseguem atingir os últimos 5% de questões no primeiro bloco de provas, o que é um resultado muito abaixo do esperado, mesmo se comparado ao grupo que gasta mais tempo nas primeiras questões na Colômbia, em que 77,5% atingem os últimos 5% de questões no primeiro bloco.

A Tabela 3 mostra, além disso, que o possível aprendizado dos alunos brasileiros em fazer a prova se reflete em uma redução significativa do tempo de resolução das primeiras questões, além de um aumento acentuado da probabilidade de chegar ao final do bloco. O grupo que gasta mais tempo no segundo bloco chega a uma probabilidade de alcançar o final do bloco superior àquela do grupo que gastou menos tempo no primeiro bloco. O grupo brasileiro que gasta menos tempo no segundo bloco chega a uma probabilidade superior ao grupo que gastou menos tempo na Colômbia no primeiro bloco.

Como as questões possuem ordem aleatória, a única coisa que se altera é a experiência de ter realizado um bloco da prova. Nesse sentido, é interessante notar que mesmo com o aumento da proporção de alunos que chegam ao final da prova aumentar no segundo bloco, a proporção de acertos também aumenta, do segundo ao quarto grupos de alunos. Esse resultado sugere que, entre os alunos que aprendem a fazer a

Tabela 3. Relação entre Tempo Médio, Pontuação e participação ao longo do PISA 2015 para o Brasil em comparação a outros países.

País	Tempo (5% Início)	Quartil (Tempo)	Tempo Max.	Prob. (>45%)	Acertos** (>45%)	Tempo (5% Intervalo)	Tempo Max.	Prob. (>95%)	Acertos** (>95%)	Prob. (>45%) e (>95%)
Brasil	2,48	1	1,24	0,547	0,512	1,82	0,91	0,881	0,460	0,404
		2	1,98	0,483	0,520		1,44	0,791	0,535	0,360
		3	3,12	0,389	0,487		2,26	0,711	0,544	0,290
		4*	9,94	0,285	0,453		7,56	0,569	0,523	0,205
Colômbia	2,07	1	0,97	0,845	0,612	1,64	0,79	0,968	0,577	0,684
		2	1,73	0,875	0,622		1,33	0,962	0,645	0,717
		3	2,76	0,824	0,583		2,13	0,950	0,640	0,674
		4*	7,89	0,775	0,539		6,38	0,920	0,613	0,617
Finlândia	1,26	1	0,66	0,946	0,831	1,11	0,57	0,986	0,787	0,769
		2	1,03	0,948	0,848		0,89	0,988	0,847	0,798
		3	1,58	0,929	0,836		1,40	0,983	0,863	0,784
		4*	4,88	0,886	0,859		4,44	0,969	0,862	0,748
Coréia do Sul	0,97	1	0,43	0,968	0,838	0,92	0,39	0,993	0,739	0,784
		2	0,75	0,961	0,862		0,70	0,994	0,862	0,796
		3	1,24	0,959	0,866		1,19	0,993	0,883	0,820
		4*	4,14	0,952	0,869		4,13	0,989	0,896	0,810

Notas: Tabela com tempo médio de resposta nas 5% primeiras questões de cada bloco para o total dos alunos por país, além do tempo máximo, probabilidade de chegar às 5% últimas questões do bloco e probabilidade de acerto dessas questões, condicional a atingi-las, para alunos divididos em 4 grupos de tamanho igual, segundo o tempo utilizado nas 5% primeiras questões. *Valores extremos (acima de 99% da distribuição) de tempo por questão removidos. **Probabilidade de acertar uma das últimas questões, dado que o aluno atingiu a questão.

Fonte: PISA 2015. Elaboração própria.

prova no segundo bloco, o efeito marginal do tempo sobre a probabilidade de acerto em novos itens no final da prova é maior do que o efeito sobre a probabilidade de acerto de itens que já seriam vistos de qualquer forma no início da prova. Em outras palavras, para aumentar a nota, vale mais a pena o aluno gastar tempo em novos itens, deixando de lado aqueles em que possivelmente tem maior dificuldade no início da prova. Esse resultado parece reforçar o argumento de que a diferença de decaimento do Brasil em relação aos demais países não se relaciona somente às habilidades socioemocionais.

Quando separamos os alunos brasileiros de escolas públicas daqueles de escolas privadas, na Tabela 4, os primeiros apresentam maior tempo de resolução, proporções menores de alunos que chegam ao final do bloco e de acertos. Com essa desagregação, podemos observar, além disso, que ambos os grupos apresentam redução grande no tempo de resposta das primeiras questões do segundo bloco em comparação ao primeiro bloco e significativo crescimento na probabilidade de chegar ao final do segundo bloco. No entanto, somente entre os alunos de escolas públicas a probabilidade de acertos parece aumentar de forma relevante, do segundo ao quarto grupos de alunos. Entre os alunos das escolas privadas, a probabilidade de acerto diminui ou se mantem relativamente constante.

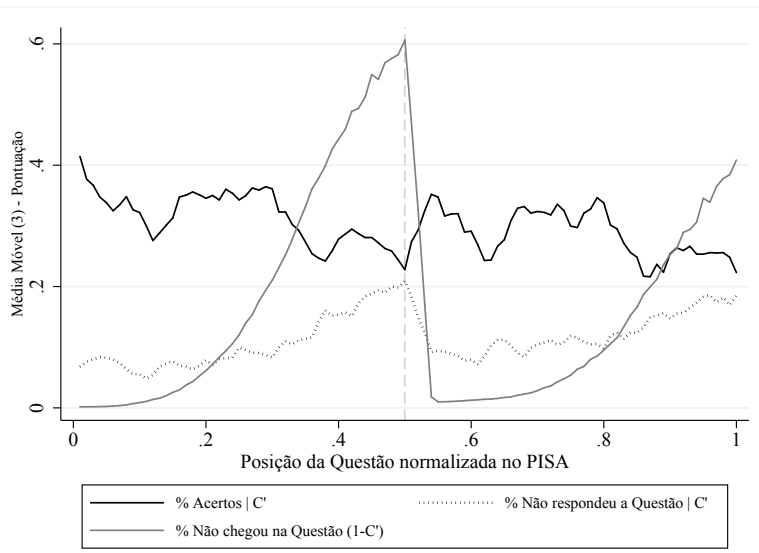
Dadas as comparações aqui apresentadas, parece intuitivo propor que um modelo para estimação do decaimento de desempenho entre diferentes grupos deva levar em conta a probabilidade de acerto condicional ao aluno ter chego à questão e o tempo gasto em cada questão, que a princípio deve exercer um efeito positivo na probabilidade de acerto das questões. A Figura 10 mostra qual seria a pontuação condicionada ao percentual de alunos brasileiros que alcançam as questões.

Tabela 4. Relação entre Tempo Médio, Pontuação e participação ao longo do PISA 2015 para escolas públicas e privadas no Brasil.

País	Tempo (5% Início)	Quartil Dist. de Tempo	Tempo Max.	Prob. (>45%)	Acertos ** (>45%)	Tempo (5% Intervalo)	Tempo Max.	Prob. (>95%)	Acertos ** (>95%)	Prob. (>45%) e (>95%)
Públicas	2,51	1	1,26	0,541	0,482	1,82	0,91	0,884	0,437	0,400
		2	2,01	0,476	0,498		1,44	0,792	0,510	0,351
		3	3,15	0,381	0,462		2,26	0,708	0,516	0,284
		4*	10,04	0,284	0,435		7,62	0,558	0,489	0,204
Privadas	2,10	1	1,08	0,591	0,695	1,70	0,90	0,872	0,627	0,441
		2	1,69	0,574	0,718		1,39	0,816	0,705	0,430
		3	2,65	0,481	0,691		2,14	0,758	0,696	0,357
		4*	7,95	0,401	0,659		6,28	0,665	0,672	0,290

Notas: Tabela com tempo médio de resposta nas 5% primeiras questões de cada bloco para o total dos alunos por país, além do tempo máximo, probabilidade de chegar às 5% últimas questões do bloco e probabilidade de acerto dessas questões, condicional a atingi-las, para alunos divididos em 4 grupos de tamanho igual, segundo o tempo utilizado nas 5% primeiras questões. *Valores extremos (acima de 99% da distribuição) de tempo por questão removidos. **Probabilidade de acertar uma das últimas questões, dado que o aluno atingiu a questão.

Fonte: PISA 2015. Elaboração própria.



Nota: Proporção de acertos e de não resposta, dado que o aluno chegou à questão, por posição normalizada da questão, e proporção de casos em que o aluno não chega na questão por posição normalizada da questão. Os dois primeiros percentuais somados, mais a proporção de respostas erradas, totaliza 100%. O eixo horizontal mostra a posição normalizada das questões, colocando o intervalo na posição 0,5 e o final da prova na posição 1.

Fonte: PISA 2015. Elaboração própria.

Figura 10. Queda de desempenho observada e porcentagem de alunos brasileiros que não respondeu às questões no PISA 2015, condicionada ao percentual de alunos que alcançam as últimas questões.

Nessa nova configuração, o decaimento da proporção de acertos se torna menos acentuada em cada bloco. As consequências da escolha de utilizar somente as questões atingidas para a estimação do decaimento são brevemente avaliadas em Borghans e Schils (2012) utilizando dados mais antigos do PISA 2009. Segundo os autores, a estimação utilizando as questões não atingidas como erradas, num modelo binário, leva à superestimação do decaimento. No entanto, atentando ao fato de que, em média, os alunos que são capazes de chegar ao final da prova têm aproveitamento de tempo melhor, esta formulação levaria a uma correlação estrita entre os fatores não observados e a posição da questão, uma vez que só os melhores alunos são capazes de responder às últimas questões, implicando em um decaimento estimado viesado. Portanto, seria necessário testar a validade desta formulação para implementá-la, o que não pode ser feito ainda neste trabalho.

Além disso, a proporção de questões não respondidas aumenta ao longo da prova. Esse aumento pode novamente ser explicado por efeitos de composição e de tempo de prova. Conforme avançamos ao longo das questões da prova, os alunos que gastaram mais tempo nas primeiras questões deixam de responder as últimas questões e não entram no cálculo da taxa de não resposta. É possível que alunos com taxas maiores de não resposta avancem mais ao longo da prova, alcançando às questões finais. Além disso, o segundo efeito é de que, o comportamento dos alunos que chegam ao final da prova pode mudar, com maiores taxas de não resposta devido ao menor tempo disponível.

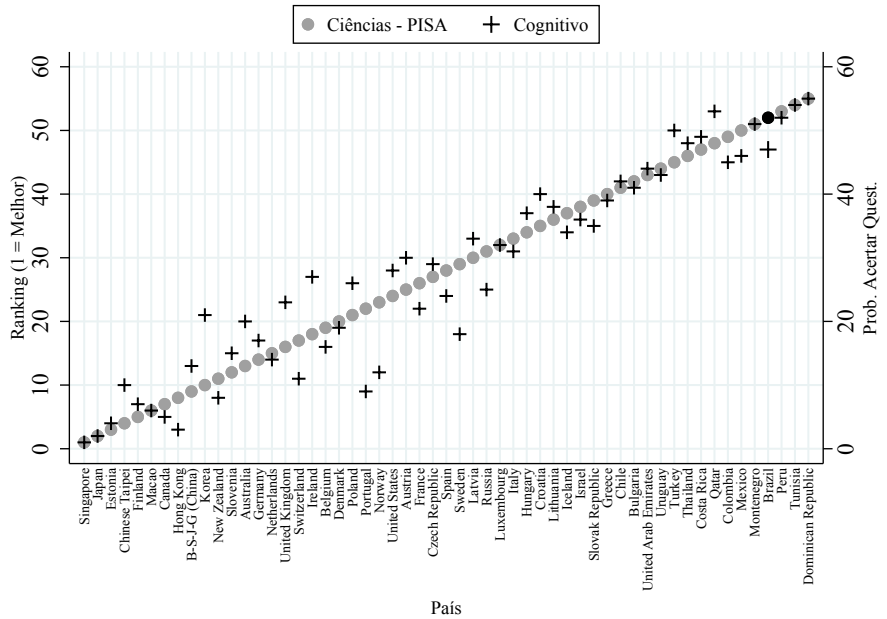
Por último, mostramos que apesar do decaimento do Brasil ser acentuado, ele não é único determinante de sua baixa posição relativa de notas entre os países participantes. No cenário contrafactual em que não há decaimento ao longo dos blocos, a variável relevante para comparar os países é a média da probabilidade estimada de acerto da primeira questão, que utilizamos como medida de habilidades cognitivas.

A Figura 11 mostra os países ordenados de acordo com um ranking das notas de Ciências,[5] numa linha de 45°, e apresenta, em destaque, qual seria a posição de cada um desses países num ranking de acertar a primeira questão da prova. A distância vertical, para cada país, entre os dois pontos que representam estes dois rankings mostra os ganhos ou perdas de posições de acordo com a variável escolhida. Entre as 55 regiões[6] para as quais temos as notas e as estimativas de habilidades cognitivas, o Brasil aparece na posição 47 em relação a essas habilidades e na posição 52 em Ciências. Esse resultado mostra que se o Brasil e todos os demais países mantivessem o mesmo desempenho do início da prova sem serem afetados pelo decaimento, sua posição relativa melhoraria cinco posições entre os últimos países do ranking.

A Figura 12 apresenta um gráfico somente para estes ganhos e perdas de posições para cada país nesses dois rankings comparados, ordenados da maior perda para o maior ganho. Dos 55 países, 24 perdem posições ao considerarmos apenas a probabilidade de acerto da primeira questão e outros 24 ganham posições. Ao observar os ganhos de outros países, podemos acreditar que um ganho de 5 posições não é desprezível, pois há apenas outros 5 países que ganham mais posições do que o Brasil.

[5] Ciências era a prova principal do exame de 2015.

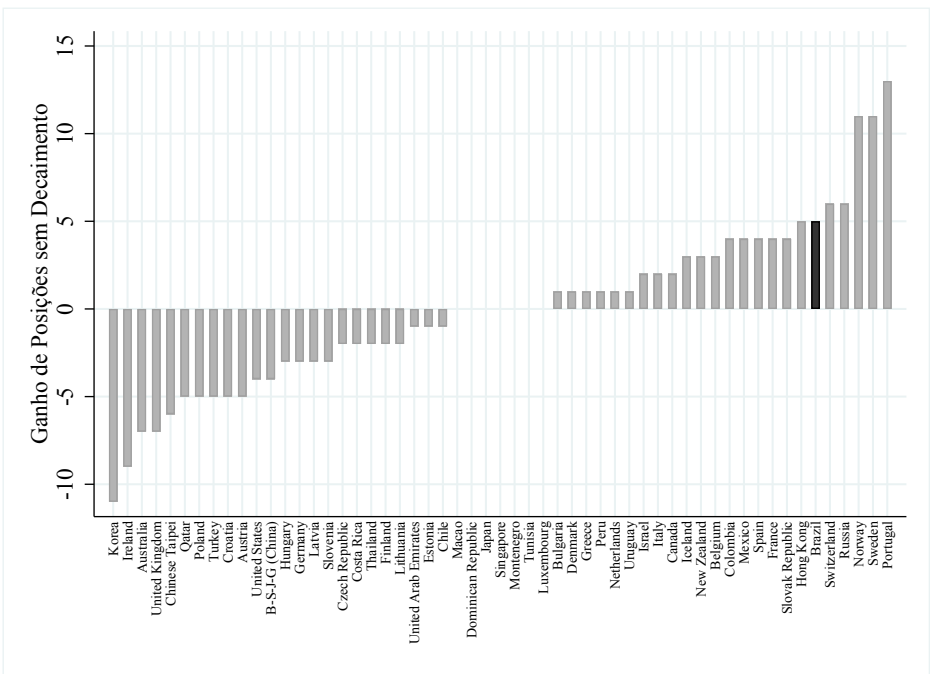
[6] Somente regiões ou países que fizeram provas do tipo CBA, mas com uma região a menos, excluindo as regiões da Espanha que fazem o PISA de modo separado.



Nota: Ranking pela probabilidade de acertar a primeira questão e ranking pela nota de ciências, para cada uma das 55 regiões. Destacamos o Brasil em preto.

Fonte: PISA 2015. Elaboração própria.

Figura 11. Ranking de Habilidades Cognitivas e das Notas de Ciências.



Nota: Ganho de posições num ranking entre a probabilidade de acertar a primeira questão e a nota de ciências, para cada uma das 55 regiões. Destacamos o Brasil em preto.

Fonte: PISA 2015. Elaboração própria.

Figura 12. Mudanças entre os Rankings de Habilidades Cognitivas e de Notas de Ciências.

Mesmo assim, o ganho de alguns países, como Noruega, Suécia e Portugal é muito mais expressivo do que o salto de posições brasileiro. Desta forma, há indícios de que o decaimento afeta de forma relevante a posição relativa do Brasil em comparação aos demais países, mas não pode ser apontado como o principal determinante do desempenho no exame.

6. Recuperação

6.1 Estimativas da descontinuidade

A medida de recuperação é o tamanho da descontinuidade apresentada no modelo apresentado na equação (3) deste trabalho e expressa pelo coeficiente $\hat{\gamma}_1$. A Tabela 5 ordena os países de acordo com a recuperação estimada, do maior para o menor. Vemos que neste ordenamento, em geral, o países que apresentam maior decaimento também apresentam maior recuperação de desempenho, sendo que o Brasil tem a maior recuperação entre os dois blocos. Peru, Portugal, México, Uruguai, Rússia, Colômbia e República Dominicana também estão entre os países com maiores descontinuidades de desempenho entre os blocos de prova e os maiores decaimentos de desempenho ao longo do exame. Este pode ser um indício de que tanto o decaimento quanto a medida de recuperação captam variações parecidas no comportamento dos alunos aos longo da prova.

Salientamos que apesar desta medida aludir a uma recuperação do desempenho, a descontinuidade não é uma dimensão positiva para as habilidades socioemocionais. Uma descontinuidade maior está associada a uma desestabilização maior por fatores externos ou motivacionais no primeiro bloco de provas, em relação aos alunos que não são prejudicados por estes fatores.

Tabela 5. Recuperação estimada para países que fizeram a prova em CBA.

País	$\hat{\gamma}_1$	País	$\hat{\gamma}_1$	País	$\hat{\gamma}_1$	País	$\hat{\gamma}_1$
Brazil	0,197	France	0,105	Hungary	0,08	Ireland	0,046
Peru	0,166	New Zealand	0,104	Denmark	0,079	Lithuania	0,046
Portugal	0,165	Israel	0,103	Switzerland	0,078	Austria	0,036
Uruguay	0,151	Norway	0,101	Thailand	0,076	Latvia	0,035
Sweden	0,14	Italy	0,1	Greece	0,076	United Kingdom	0,028
Mexico	0,138	Macao	0,1	Qatar	0,073	Slovenia	$0{,}025^{s5}$
Russian Federation	0,13	Germany	0,098	Estonia	0,069	Singapore	0,024
Costa Rica	0,12	Belgium	0,091	Finland	0,066	Chinese Taipei	0,021
Dominican Republic	0,119	Slovak Republic	0,09	Australia	0,066	United Arab Emirates	0,02
Colombia	0,119	United States	0,086	Czech Republic	0,06	Hong Kong	$0{,}015^{s10}$
Spain	0,118	B-S-J-G (China)	0,086	Iceland	0,058	Netherlands	$0{,}009^{ns}$
Bulgaria	0,11	Japan	0,084	Poland	0,058	Korea	$0{,}009^{ns}$
Chile	0,109	Montenegro	0,082	Canada	0,056	Turkey	$0{,}002^{ns}$
Luxembourg	0,109	Tunisia	0,08	Croatia	0,055		

Notas: Tabela com os valores estimados da recuperação de desempenho dos alunos entre os pontos antes e depois do intervalo, a partir da equação (2). Todos os coeficientes são significativos a menos de 1%, a não ser os valores marcados com: ^{s5} significativo somente a 5%; ^{s10} significativo somente a 10%; ^{ns} não significativo a 10%.
Fonte: PISA 2015. Elaboração própria.

Para entender quais habilidades dos alunos esta medida de recuperação é capaz de captar podemos examinar as correlações entre as medidas de habilidades cognitivas (probabilidade de acerto da primeira questão) e não-cognitivas (decaimento e recuperação), sem nenhuma pretensão de estimar relações causais entre elas. A Tabela 6 mostra as regressões das medidas de habilidades cognitivas nas outras duas possíveis medidas de habilidades não cognitivas. Podemos verificar que a recuperação estimada não se mostra correlacionada com a nota em Ciências do PISA 2015 ou com a probabilidade de acertar a primeira questão da prova, mas fortemente correlacionada com a própria medida de decaimento. Assim, há evidências para que a recuperação também seja uma boa *proxy* para as habilidades socioemocionais ou outros fatores alternativos à habilidade cognitiva que influem no desempenho dos alunos durante a prova.

6.2 Recuperação e habilidades não cognitivas

Para esclarecer que tipo de habilidades a medida de recuperação entre os dois blocos pode capturar, replicamos as estimações principais apresentadas em Hanushek e Woessmann (2012) e Balart et al. (2018) de como as habilidades não cognitivas influenciam o crescimento de longo prazo dos países, a fim de promover um certo tipo de validação externa.

Hanushek e Woessmann (2012) desenvolvem uma nova métrica para a distribuição do desempenho educacional em países que pode descrever melhor a distribuição de habilidades cognitivas dentro dos países e ao longo tempo. Apresentando regressões de crescimento entre países com uma relação estreita entre desempenho educacional e crescimento do PIB. Os autores mostram que essa relação é estável através de análises de sensibilidade das especificações, períodos de tempo e amostras de países, utilizando diversas medidas de desempenho educacional, inclusive dados do PISA. Os autores propõem um construto (referenciado posteriormente como HW-Index) para capturar o desenvolvimento do capital humano nos países e mostram seu efeito sobre o crescimento de longo prazo dos mesmos. Balart et al. (2018) se valem da mesma metodologia para as regressões de longo prazo e incluem as estatísticas decompostas a partir da

Tabela 6. Regressões de medidas de habilidades cognitivas em habilidades socioemocionais.

	(1)	(2)	(3)
	Ciências PISA 2015	$P[Y_0 = 1]$	Decaimento
Decaimento	-709,3***	-1,048**	
	(3,67)	(2,89)	
Recuperação ($\hat{\gamma}_1$)	77,11	0,210	0,735***
	(0,41)	(0,60)	(8,60)
Constante	540,8***	0,595***	0,0380***
	(40,82)	(23,89)	(4,85)
N	55	55	55
R^2 Ajustado	0,318	0,187	0,575

Notas: Estatística t entre parênteses; * $p < 0{,}10$; ** $p < 0{,}05$; *** $p < 0{,}01$.
Fonte: PISA 2015. Elaboração própria.

nota do PISA (desempenho inicial e decaimento) como representativos para o capital humano, sendo o decaimento uma medida adicional para as habilidades não cognitivas na formação de capital humano. Mostrando que o decaimento é uma medida tão boa quanto as medidas anteriores para as habilidades cognitivas e que o efeito estimado do decaimento no crescimento (habilidades não cognitivas) é aproximadamente igual ao efeito estimado do desempenho inicial (habilidades cognitivas). Os autores mostram também que o decaimento como medida de habilidades não cognitivas é constante ao longo do tempo e que as próprias habilidades não cognitivas também são constantes ao longo do tempo, utilizando os dados do PISA para os anos de 2003, 2006 e 2009.

A análise empírica do efeito das habilidades sobre crescimento econômico a ser replicada é uma regressão padrão de crescimento, incluindo a pontuação no PISA como uma *proxy* para o capital humano. Essa pontuação é decomposta em medidas que separam as habilidades cognitivas das não cognitivas: as pontuações do PISA no desempenho inicial (Z_{0p}), expresso na probabilidade estimada de acerto da primeira questão, para cada país p, e o decaimento do desempenho durante o teste (D_p). Incluiremos no modelo a recuperação estimada para cada país ($\hat{\gamma}_{1p}$), como uma medida que pode ser complementar ou substituta do decaimento na identificação das habilidades não cognitivas.

Usamos os mesmos dados sobre o crescimento econômico (Hanushek & Woessmann, 2012), o mesmo crescimento de longo prazo (1960–2000), controles idênticos, mas utilizaremos o desempenho estimado em 2015 para a amostra de países presentes tanto em Balart et al. (2018) e nos dados do PISA 2015:

$$G_p = \delta_0 + \delta_1 Z_{0p} + \delta_2 D_p + \delta_3 \hat{\gamma}_{1p} + \delta_4 GDP1960_p + \sum_c \delta_c T_{cp} + \theta_p \,. \tag{4}$$

A equação (4) apresenta o modelo a ser estimado por MQO, apenas com o objetivo de validar a recuperação como uma medida de habilidades não cognitivas. Este modelo tem como variável dependente a taxa média de crescimento anual do PIB per capita de 1960–2000 (G_p). Como variáveis explicativas incluímos também uma constante e o PIB per capita em 1960 ($GDP1960_p$). Os controles sintetizados em $\sum_c \delta_c T_{cp}$ são o grau abertura da economia, a proteção contra a expropriação, a fertilidade dos solos e uma *dummy* para a localização tropical descritos em Hanushek e Woessmann (2012). A Tabela 7 apresenta os resultados das regressões, incluindo somente o decaimento, a recuperação e incluindo ambas as medidas.

Os resultados das regressões de cada medida de habilidades não cognitivas, os modelos 1 e 3, que não incluem todos controles, mostram que a medida de recuperação pode cumprir o mesmo papel que a medida de decaimento em explicar as diferenças de crescimento de longo prazo entre os países da amostra. Além de o efeito da recuperação ser robusto à introdução de controles (modelos 2 e 4) e à estimação do modelo contando com as duas medidas (modelo 5). Deste modo, há evidencias convincentes de que a recuperação de desempenho entre os dois blocos captura variações nas habilidades não cognitivas dos alunos.

Hanushek e Woessmann (2012) apresentam uma medida consistente a níveis nacionais que seja capaz de sintetizar o desempenho de alunos em vários períodos e avaliações, chamado de HW-Index em Balart et al. (2018). Combinando os ajustes nos níveis de pontuações e o ajuste nas variações, calculam pontuações padronizadas de

Tabela 7. Regressões de crescimento em medidas de habilidades cognitivas e habilidades socioemocionais.

	(1)	(2)[e]	(3)	(4)[e]	(5)[e]
Cognitivo (Z_0)	10,65***	11,04*	11,61***	10,35**	13,78**
	(4,76)	(2,71)	(6,77)	(3,23)	(3,60)
Decaimento	-7,460*	-2,692			8,129
	(2,23)	(0,76)			(1,55)
Recuperação ($\hat{\gamma}_1$)			-8,088**	-5,237*	-9,946*
			(3,32)	(2,19)	(2,59)
N	36	34	36	34	34
R^2 Ajustado	0,772	0,802	0,804	0,829	0,838

Notas: Variável dependente: taxa média de crescimento anual do PIB per capita de 1960–2000; Regressões incluem uma constante e PIB per capita em 1960. [e]Incluindo controles de abertura da economia, proteção contra a expropriação, fertilidade e localização tropical. Estatística t entre parênteses; * $p < 0{,}10$; ** $p < 0{,}05$; *** $p < 0{,}01$.

Fonte: PISA 2015. Elaboração própria.

escores dos testes cognitivos para todos os países em todas as avaliações disponíveis no período de 1964 a 2003, agregando neste índice os escores ao longo do tempo, para diferentes idades e matérias. Desta forma, o HW-Index é representação mais completa dos níveis de capital humano que podem ser obtidos a partir do desempenho individual de alunos em exames padronizados.

Um terceiro exercício proposto para a validação da recuperação como uma medida representativa para as habilidades não cognitivas é o estudo das correlações entre o HW-Index e as medidas de habilidades cognitivas (probabilidade de acerto da primeira questão) e não-cognitivas (decaimento e recuperação). Mais uma vez, sem a pretensão de estimar relações causais entre essas variáveis.

A Tabela 8 mostra as regressões do HW-Index nas duas possíveis medidas de habilidades não cognitivas e na medida de habilidades cognitivas. Podemos verificar que quando incluídos separadamente, tanto o decaimento quanto a recuperação (respectivamente, modelos 1 e 2) são significativamente correlacionados com o índice, assim como a probabilidade de acerto da primeira questão. Ao contrário do que acontece com o decaimento, a correlação da recuperação com índice é robusta à estimação utilizando ambas as medidas simultaneamente (modelo 3). Com isso, vemos que o nível do capital humano pode ser separado em duas dimensões: cognitiva e não cognitiva, como propõe Balart et al. (2018). Vemos ainda que podemos supor que a recuperação estimada seja uma *proxy* melhor para as habilidades não cognitivas (ou outra segunda dimensão do capital humano) do que o decaimento.

Apesar de o período coberto pelos dados de crescimento ser desconexo com o período de extração das medidas de capital humano, as afirmações apresentadas em Balart et al. (2018) e Hanushek e Woessmann (2012) indicam a validade de se utilizar este tipo de dados, no nosso caso para o PISA 2015. Os autores argumentam que as variáveis de capital humano e as estatísticas decompostas do PISA são, de certa forma, constantes ao longo do tempo e das edições da prova. Uma vez que o objetivo desta sessão é apenas validar a medida de recuperação e sua relação com o capital humano e

Tabela 8. Regressões do HW-Index nas medidas decompostas da nota do PISA 2015.

	(1)	(2)	(3)
	HW-Index 2012	HW-Index 2012	HW-Index 2012
Cognitivo (Z_0)	5,232***	5,457***	5,689***
	(5,99)	(9,18)	(7,37)
Decaimento	-3,009***		1,241
	(3,78)		(0,71)
Recuperação ($\hat{\gamma}_1$)		-3,458***	-4,309*
		(4,32)	(2,62)
Constante	2,324***	2,191***	2,015***
	(4,38)	(6,35)	(4,19)
N	36	36	36
R^2 Ajustado	0,835	0,877	0,876

Notas: Estatística t entre parênteses; * $p < 0{,}10$; ** $p < 0{,}05$; *** $p < 0{,}01$.
Fonte: PISA 2015 e Hanushek e Woessmann (2012).

não inferir causalidade desta para com o crescimento de longo prazo, os coeficientes apresentados por estas estimativas devem sem interpretados de forma cautelosa.

7. Conclusão e desenvolvimentos futuros

Nesse trabalho, nós examinamos os motivos que levam o Brasil a ter baixo desempenho no exame do PISA 2015 em comparação com outros países, além de propor uma medida alternativa para a mensuração objetiva de habilidades não cognitivas, a partir de uma descontinuidade no desempenho ao longo do exame. Nós exploramos novas características da prova em 2015 que fazem os alunos responderem sequencialmente às questões para determinar quais aspectos desta avaliação são relacionados aos diferentes tipos de habilidades e quais deles influenciam o desempenho relativamente ruim do Brasil.

Nós utilizamos a variação exógena da posição de cada questão para identificar efeitos de habilidades socioemocionais a partir de uma medida de decaimento na probabilidade de acerto dos itens ao longo da prova. Também calculamos uma medida de habilidades cognitivas, a partir da probabilidade de acerto da primeira questão do exame. A principal hipótese por trás dessas medidas é de que no início da prova somente as habilidades cognitivas afetam a probabilidade de acertar uma questão, e ao longo da prova, em contraste, a probabilidade de acertos declina sob a influência de personalidade, como motivação e empenho.

Mostramos que existe uma descontinuidade entre os blocos de prova e que esta pode ser entendida como uma recuperação de desempenho. Discutimos que a interpretação desta recuperação como uma medida de habilidades socioemocionais pode ser superior ao uso do decaimento para representar esta dimensão. No entanto, o decaimento apresenta uma abordagem mais prática do problema: é possível construir um ordenamento onde não existe decaimento a partir da decomposição do rendimento da prova entre desempenho inicial e queda de desempenho. Sendo que o cenário

contrafactual sem a influência de habilidades socioemocionais seria claramente a representação apenas do desempenho inicial. Para a recuperação, é difícil construir um cenário contrafactual com uma abordagem tão clara.

Nossos resultados indicam que o Brasil possui probabilidade comparativamente baixa de acerto da primeira questão, um dos maiores declínios de desempenho ao longo da prova e a maior descontinuidade de desempenho entre os dois blocos de provas. O exercício contrafactual sugere que não somente o nível das habilidades cognitivas influencia a posição relativa do Brasil num ranking de desempenho entre os países. Mesmo que o ganho de posições na ausência de decaimento não seja muito grande, ainda é um dos maiores observados entre os países que fizeram as provas do tipo CBA.

Nossa análise dos determinantes do decaimento mostra que o mal desempenho do Brasil se deve especialmente ao fato de que grande parte dos respondentes não conseguirem chegar ao fim da prova, o que pode estar relacionado à demora para entender o enunciado da questão e para desenvolver o raciocínio sobre a resposta. Dessa forma, o decaimento parece estar associado também às habilidades cognitivas.

Adicionalmente, o desempenho ruim do Brasil pode estar ligado à dificuldade de se fazer exames como o PISA. Enquanto o tempo médio de resposta das primeiras questões do bloco após o intervalo são consideravelmente menores do que aqueles das primeiras questões do primeiro bloco, a probabilidade de chegar ao final do segundo bloco é consideravelmente maior do que a probabilidade de chegar ao final do primeiro bloco. Dada a aleatorização da ordem das questões, aspectos relacionados à dificuldade de se responder às questões se mantêm constantes ao longo da prova, de modo que os alunos brasileiros aprendem a fazer a prova entre os blocos. O mesmo não ocorre de forma tão acentuada em países com as maiores notas. As taxas de acerto dos alunos brasileiros que chegam ao final do segundo bloco são em geral maiores do que as daqueles que chegam ao final do primeiro bloco, o que sugere que o tempo é gasto de forma mais eficiente no segundo bloco. Dessa forma, é possível que o desempenho brasileiro aumentasse, caso os alunos gastassem menos tempo nas questões iniciais em que têm mais dificuldade, e utilizassem esse tempo para alcançar as questões finais da prova. Esse resultado é elevado especialmente para alunos da rede pública.

Assim como em Akyol et al. (2018), numa análise contrafactual de "equilíbrio geral", onde todos os alunos não seriam prejudicados pelo decaimento, ou pela baixa motivação como os autores propõe, o Brasil não ganha tantas posições quanto se esperaria num ranking relativo ao desempenho dos países, apesar deste ganho não ser desprezível. Nossos resultados corroboram a conclusão de que isto se deve ao conhecimento dos alunos "não sérios" já ser muito baixo, estendendo a explicação para o fato de que poucos alunos brasileiros realizam o exame utilizando a melhor estratégia possível, em termos de tempo de prova e aproveitamento, para responderam a todas as questões do exame.

O PISA vem, ao longo das suas últimas edições, ampliando a coleta de dados socioeconômicos e socioemocionais auxiliares ao exame, com o uso destes dados –por exemplo a riqueza familiar ou atitude e motivação em relação ao esforço – seria possível aprofundar a análise das diferenças de decaimento e recuperação, validando as medidas objetivas aqui propostas a partir de outros construtos socioemocionais subjetivos reportados no exame, além de testar a hipótese levantada em Marchioni

(2017) de que as diferenças de decaimento entre escolas públicas e privadas seriam advindas da diferença de renda entre alunos e tipo de escola seria apenas uma *proxy* para esta condição.

Desenvolvimentos futuros sobre o tema devem, portanto, considerar de que forma o decaimento médio do desempenho dos alunos brasileiros pode ser mediado pela porcentagem de alunos que conseguem atingir as últimas questões da prova e em que extensão esta porcentagem ou o tempo médio de resolução de questões podem contribuir para uma medida de habilidades não cognitivas mais acurada entre os estados e, também, a extensão da aplicabilidade da recuperação entre os blocos como medida de habilidades socioemocionais, algumas destas questões já são adereçadas em Akyol et al. (2018).

As formulações apresentadas e também referenciadas neste trabalho (Borghans & Schils, 2012; Marchioni, 2017; Balart et al., 2018) estão limitadas, em termos práticos, à estimação de uma tendência linear da probabilidade de acerto entre a última e a primeira questão, não capturando bem a variação desta probabilidade em torno do intervalo e dificultando a introdução do tempo como variável explicativa. O intervalo parece intermediar alguma relação entre o tempo médio e a probabilidade de acerto das questões, como é demostrado a partir da medida de recuperação. Com a estimação desta descontinuidade, podem sem propostos modelos que sejam mais adequadas à introdução do tempo como uma variável explicativa do desempenho.

Ao menos para o caso brasileiro, podemos notar que os alunos têm desempenho mais eficiente em termos de tempo por questão no segundo bloco de provas[7] e o decaimento observado é menor em relação ao decaimento do primeiro bloco. Esse resultado sugere que, ao longo do exame, o desempenho dos alunos brasileiros não é exclusivamente prejudicado pelo cansaço ou fadiga, mas que há algum aprendizado quanto à natureza da prova e um maior entendimento de como responder (ou não responder) às questões para ser capaz de chegar ao final do exame.

Referências bibliográficas

Akyol, Ş. P., Krishna, K., & Wang, J. (2018, August). *Taking PISA seriously: How accurate are low stakes exams?* (Working Paper Nº 24930). Cambridge, MA: National Bureau of Economic Research (NBER). http://dx.doi.org/10.3386/w24930

Albano, A. D. (2013). Multilevel modeling of item position effects. *Journal of Educational Measurement*, *50*(4), 408–426. http://dx.doi.org/10.1111/jedm.12026

Almund, M., Duckworth, A. L., Heckman, J., & Kautz, T. (2011). Personality psychology and economics. *In* E. Hanushek, S. Machin, & L. Woessmann (Orgs.), *Handbook of the economics of education* (Vol. 4, pp. 1–181). Amsterdam: Elsevier.

Balart, P., Oosterveen, M., & Webbink, D. (2018). Test scores, noncognitive skills and economic growth. *Economics of Education Review*, *63*, 134–153. http://dx.doi.org/10.1016/j.econedurev.2017.12.004

Borghans, L., Duckworth, A. L., Heckman, J. J., & Ter Weel, B. (2008). The economics and psychology of personality traits. *Journal of Human Resources*, *43*(4), 972–1059. http://dx.doi.org/10.3368/jhr.43.4.972

[7] As tabelas 5 e 6, demostram que em todos os casos observados a [Prob. > 95 %] é sempre maior do que [Prob. > 45 %].

Borghans, L., & Schils, T. (2012). *The leaning tower of Pisa: Decomposing achievement test scores into cognitive and noncognitive components.* http://www.sole-jole.org/13260.pdf

Davis, J., & Ferdous, A. (2005, 12 de abril). Using item difficulty and item position to measure test fatigue. *In* M. Cochran-Smith & A. M. Villegas (Chair), *American Educational Research Association 2005 Annual Meeting*, Montreal, Quebéc. https://convention2.allacademic.com/one/aera/aera05/index.php?click_key=1&cmd=Multi+Search+Search+Load+Publication&publication_id=9091&PHPSESSID=l16qpqjsj53raqj7cpujk2rsul

Duckworth, A. L., Quinn, P. D., Lynam, D., Loeber, R., Stouthamer-Loeber, M., Moffitt, T. E., & Caspi, A. (2009). *What intelligence tests test: Individual differences in test motivation and IQ.* ResearchGate. https://www.researchgate.net/publication/237626525_What_Intelligence_Tests_Test_Individual_Differences_in_Test_Motivation_and_IQ

Eklöf, H. (2007). Test-taking motivation and mathematics performance in TIMSS 2003. *International Journal of Testing*, *7*(3), 311–326. http://dx.doi.org/10.1080/15305050701438074

Hanushek, E. A., & Kimko, D. D. (2000). Schooling, labor-force quality, and the growth of nations. *The American Economic Review*, *90*(5), 1184–1208. http://dx.doi.org/10.1257/aer.90.5.1184

Hanushek, E. A., & Woessmann, L. (2012). Do better schools lead to more growth? Cognitive skills, economic outcomes, and causation. *Journal of Economic Growth*, *17*(4), 267–321. http://dx.doi.org/10.1007/s10887-012-9081-x

Heckman, J. J., Pinto, R., & Savelyev, P. (2013). Understanding the mechanisms through which an influential early childhood program boosted adult outcomes. *The American Economic Review*, *103*(6), 2052–2086. http://dx.doi.org/10.1257/aer.103.6.2052

Heckman, J. J., Stixrud, J., & Urzua, S. (2006). The effects of cognitive and noncognitive abilities on labor market outcomes and social behavior. *Journal of Labor Economics*, *24*(3), 411–482. http://dx.doi.org/10.1086/504455

Marchioni, C. G. (2017). *Habilidades no cognitivas en América Latina: Una medición desde pruebas estandarizadas* (Tesis de maestria, Universidad Nacional de La Plata, La Plata, Argentina). http://dx.doi.org/0.35537/10915/70188

OCDE. (s. d.). *PISA 2015 database.* Organização para a Cooperação e Desenvolvimento Econômico: Programme for International Students Assessment. https://www.oecd.org/pisa/data/2015database/

OCDE. (2017). *Pisa 2015: Technical report*. OCDE. Acessado em abril de 2017: http://www.oecd.org/pisa/data/2015-technical-report/

Segal, C. (2012). Working when no one is watching: Motivation, test scores, and economic success. *Management Science*, *58*(8), 1438–1457. http://dx.doi.org/10.1287/mnsc.1110.1509

Apêndice.

Tabela A-1. Relação entre Pontuação, participação e Tempo Médio ao longo do PISA 2015.

	Pontuação						Não chega na Questão						Tempo Médio (Min.)					
	(Percentual de Prova)						(Percentual de Prova)						(Percentual de Prova)					
País	5	25	50	55	75	95	5	25	50	55	75	95	5	25	50	55	75	95
Korea	0,62	0,55	0,49	0,63	0,50	0,52	0,00	0,03	0,04	0,00	0,00	0,00	1,03	1,05	1,08	0,91	0,97	0,86
Chinese Taipei	0,60	0,60	0,54	0,63	0,55	0,54	0,00	0,03	0,05	0,00	0,02	0,00	1,14	1,45	1,32	1,06	1,35	0,97
Netherlands	0,59	0,56	0,50	0,58	0,53	0,50	0,00	0,00	0,03	0,00	0,00	0,00	1,25	1,22	1,10	1,03	1,02	0,94
Slovenia	0,57	0,49	0,43	0,56	0,46	0,48	0,00	0,01	0,06	0,00	0,00	0,01	1,28	1,27	1,23	1,02	1,08	0,95
Finland	0,61	0,60	0,49	0,63	0,54	0,58	0,00	0,01	0,08	0,00	0,00	0,02	1,28	1,35	1,31	1,14	1,19	1,07
United Kingdom	0,53	0,53	0,42	0,53	0,47	0,48	0,00	0,02	0,06	0,00	0,01	0,01	1,31	1,36	1,22	1,13	1,14	0,96
Croatia	0,50	0,50	0,37	0,55	0,44	0,39	0,00	0,02	0,12	0,00	0,00	0,02	1,31	1,37	1,34	1,15	1,20	1,10
Ireland	0,56	0,54	0,42	0,57	0,49	0,52	0,00	0,01	0,08	0,00	0,00	0,01	1,37	1,41	1,35	1,28	1,25	1,10
Austria	0,55	0,50	0,47	0,56	0,44	0,49	0,00	0,00	0,07	0,00	0,00	0,02	1,39	1,30	1,27	1,19	1,11	1,06
Canada	0,57	0,54	0,44	0,56	0,49	0,50	0,00	0,01	0,08	0,00	0,00	0,02	1,40	1,44	1,22	1,14	1,18	1,03
Hong Kong	0,61	0,64	0,52	0,65	0,57	0,58	0,00	0,04	0,08	0,00	0,02	0,01	1,40	1,70	1,37	1,35	1,50	0,94
Iceland	0,51	0,46	0,41	0,52	0,42	0,37	0,00	0,00	0,10	0,02	0,00	0,05	1,41	1,39	1,21	1,27	1,15	1,00
Poland	0,54	0,53	0,39	0,56	0,50	0,49	0,00	0,02	0,10	0,00	0,01	0,02	1,41	1,43	1,35	1,24	1,26	1,02
Singapore	0,62	0,58	0,50	0,63	0,54	0,60	0,00	0,02	0,08	0,00	0,00	0,01	1,42	1,54	1,35	1,16	1,31	1,04
Macao	0,63	0,54	0,51	0,60	0,57	0,53	0,00	0,00	0,11	0,01	0,00	0,05	1,44	1,60	1,41	1,42	1,46	1,13
Germany	0,60	0,55	0,42	0,63	0,51	0,52	0,00	0,04	0,14	0,00	0,02	0,03	1,47	1,48	1,34	1,23	1,31	1,11
Japan	0,62	0,55	0,44	0,64	0,52	0,56	0,00	0,03	0,14	0,00	0,01	0,03	1,47	1,57	1,55	1,33	1,43	1,06
Estonia	0,61	0,61	0,52	0,62	0,55	0,54	0,00	0,01	0,07	0,01	0,01	0,02	1,47	1,45	1,36	1,26	1,27	1,14
Lithuania	0,52	0,48	0,33	0,52	0,42	0,38	0,00	0,03	0,08	0,00	0,01	0,01	1,48	1,41	1,25	1,18	1,14	1,02
Belgium	0,58	0,55	0,39	0,59	0,49	0,46	0,00	0,03	0,16	0,00	0,02	0,07	1,48	1,51	1,36	1,22	1,33	1,11
Norway	0,58	0,54	0,38	0,58	0,46	0,43	0,00	0,03	0,11	0,00	0,02	0,04	1,48	1,46	1,34	1,23	1,27	1,08
Switzerland	0,58	0,53	0,39	0,57	0,47	0,47	0,00	0,02	0,14	0,00	0,01	0,03	1,49	1,42	1,24	1,19	1,17	0,98
Denmark	0,56	0,51	0,36	0,56	0,45	0,45	0,00	0,03	0,11	0,00	0,02	0,02	1,50	1,49	1,15	1,18	1,27	1,07
Hungary	0,51	0,51	0,37	0,54	0,43	0,43	0,00	0,04	0,14	0,00	0,01	0,04	1,50	1,41	1,35	1,20	1,31	1,02
Turkey	0,43	0,37	0,27	0,45	0,32	0,27	0,00	0,01	0,04	0,00	0,01	0,00	1,50	1,53	1,21	1,25	1,25	1,01
Czech Republic	0,58	0,51	0,42	0,56	0,47	0,50	0,00	0,01	0,10	0,00	0,00	0,03	1,51	1,42	1,50	1,23	1,21	1,10
Australia	0,54	0,51	0,37	0,52	0,44	0,42	0,00	0,04	0,14	0,01	0,02	0,06	1,51	1,55	1,23	1,25	1,32	1,02
Latvia	0,52	0,54	0,37	0,57	0,46	0,46	0,00	0,04	0,09	0,00	0,03	0,02	1,52	1,50	1,43	1,28	1,39	1,13
United States	0,55	0,52	0,36	0,55	0,46	0,46	0,00	0,03	0,16	0,00	0,02	0,04	1,53	1,60	1,28	1,20	1,35	1,03
B-S-J-G (China)	0,61	0,61	0,47	0,63	0,56	0,47	0,00	0,04	0,08	0,00	0,02	0,01	1,54	1,56	1,46	1,29	1,42	0,98
Spain	0,56	0,54	0,41	0,56	0,47	0,44	0,00	0,01	0,14	0,00	0,00	0,04	1,56	1,51	1,35	1,31	1,29	1,14
France	0,58	0,51	0,45	0,54	0,46	0,45	0,00	0,00	0,09	0,01	0,01	0,04	1,57	1,47	1,37	1,45	1,25	1,05
Luxembourg	0,54	0,48	0,33	0,53	0,43	0,42	0,00	0,02	0,21	0,00	0,01	0,04	1,58	1,54	1,35	1,25	1,25	1,06
Qatar	0,36	0,32	0,21	0,34	0,26	0,27	0,07	0,13	0,09	0,08	0,09	0,07	1,58	1,37	0,89	1,18	1,04	0,77
New Zealand	0,57	0,53	0,35	0,60	0,48	0,44	0,00	0,04	0,18	0,00	0,02	0,08	1,61	1,63	1,21	1,30	1,32	1,04
Israel	0,53	0,48	0,30	0,51	0,41	0,35	0,03	0,05	0,19	0,03	0,04	0,05	1,63	1,46	1,12	1,25	1,17	1,00
Sweden	0,56	0,52	0,31	0,57	0,44	0,42	0,00	0,04	0,21	0,00	0,02	0,07	1,64	1,56	1,24	1,30	1,33	1,04
Chile	0,53	0,46	0,28	0,50	0,38	0,37	0,00	0,02	0,18	0,00	0,00	0,06	1,67	1,58	1,26	1,38	1,39	1,11
Portugal	0,56	0,51	0,29	0,54	0,42	0,38	0,00	0,04	0,26	0,00	0,01	0,09	1,68	1,63	1,36	1,32	1,35	1,09
Italy	0,58	0,53	0,35	0,57	0,45	0,45	0,00	0,02	0,11	0,00	0,01	0,03	1,68	1,63	1,43	1,33	1,37	1,09
Slovak Republic	0,51	0,46	0,37	0,48	0,39	0,35	0,00	0,01	0,10	0,00	0,01	0,07	1,69	1,45	1,30	1,30	1,21	1,01
United Arab Emirates	0,45	0,42	0,29	0,46	0,32	0,35	0,00	0,04	0,06	0,01	0,04	0,03	1,70	1,58	1,31	1,31	1,40	0,98
Greece	0,52	0,47	0,36	0,50	0,41	0,38	0,00	0,00	0,07	0,00	0,00	0,02	1,73	1,61	1,34	1,37	1,37	1,06
Montenegro	0,41	0,32	0,24	0,41	0,27	0,24	0,00	0,02	0,14	0,01	0,01	0,07	1,73	1,36	1,24	1,27	1,16	0,93
Costa Rica	0,42	0,37	0,19	0,42	0,29	0,28	0,00	0,06	0,29	0,01	0,03	0,11	1,85	1,70	1,27	1,45	1,47	1,08
Bulgaria	0,48	0,42	0,31	0,45	0,35	0,32	0,00	0,01	0,16	0,00	0,00	0,05	1,90	1,49	1,26	1,33	1,31	1,01
Russian Federation	0,54	0,48	0,37	0,55	0,43	0,38	0,00	0,02	0,18	0,01	0,02	0,12	1,98	1,70	1,47	1,56	1,43	1,16
Uruguay	0,46	0,40	0,20	0,46	0,30	0,28	0,00	0,06	0,26	0,00	0,03	0,09	1,99	1,64	1,15	1,48	1,43	1,01
Thailand	0,42	0,40	0,29	0,41	0,32	0,28	0,00	0,01	0,18	0,01	0,01	0,11	2,00	1,71	1,59	1,59	1,48	1,14
Colombia	0,45	0,38	0,18	0,47	0,32	0,29	0,00	0,05	0,20	0,00	0,03	0,08	2,03	1,81	1,16	1,57	1,63	1,11
Mexico	0,42	0,33	0,20	0,40	0,29	0,28	0,00	0,05	0,33	0,00	0,02	0,14	2,10	1,75	1,49	1,58	1,50	1,10
Dominican Republic	0,32	0,22	0,08	0,34	0,17	0,20	0,00	0,04	0,08	0,00	0,03	0,02	2,12	1,62	0,61	1,64	1,32	0,82
Brazil	0,38	0,30	0,09	0,39	0,25	0,15	0,00	0,17	0,62	0,01	0,09	0,40	2,42	1,85	1,24	1,73	1,59	1,00
Peru	0,36	0,28	0,20	0,34	0,24	0,20	0,00	0,08	0,40	0,01	0,02	0,22	2,58	1,80	1,85	2,06	1,65	1,25
Tunisia	0,35	0,27	0,11	0,33	0,20	0,16	0,00	0,08	0,22	0,07	0,12	0,20	2,78	1,82	1,19	1,79	1,54	0,91

Fonte: PISA 2015. Elaboração própria.

r b e
REVISTA BRASILEIRA DE ECONOMIA
DOI 10.5935/0034-7140.20200011
ISSN 1806-9134 (online)
FGV
FUNDAÇÃO GETULIO VARGAS

Evidence on the Determinants of Productivity in Brazil, 2004–2014

Thais Andreia Araujo de Souza [*]
Marina Silva da Cunha [†]

Contents

1. Introduction 197
2. Theoretical and empirical review .198
3. Methodological Procedures 206
4. Results and Discussions.....210
5. Final Considerations 216

Keywords
Labor productivity, determinants, economic growth, infrastructure

JEL Codes
047 J24 043

Abstract · Resumo

No Brasil, a produtividade tem tido baixo desempenho desde a década de 1980. Então, considerando a sua importância para o crescimento econômico, é importante verificar modos de estimular o seu desempenho. Desse modo, este estudo pretende verificar como alguns determinantes influenciaram a produtividade, sendo usada a metodologia de vetores autorregressivos estruturais. Foi verificado que efeitos das melhoras nos determinantes somente ocorreriam em um maior horizonte de tempo, também que a infraestrutura teve um maior efeito na produtividade, tanto no curto quanto longo prazo. Portanto, melhoras em termos de infraestrutura têm um maior efeito na produtividade, e consequentemente no crescimento econômico.

1. Introduction

Since the 1980s Brazil has been characterized by low productivity, with some years of stagnation and even some growth, but low and soon reversed. At the beginning of the 2000s there was an increase in the growth of Brazilian production, accompanied by an increase in productivity in the country, but with the advent of the international crisis of 2008, this situation ended. Following the recovery of the international crisis, Brazil has followed a scenario of low productivity growth that has persisted, stagnating according to De Negri and Cavalcante (2014).

As mentioned in the literature, the short-run growth in the early 2000s was sustained by the improvement of the terms of trade, which benefited Brazil's situation on the international scenario by stimulating the production of agricultural products and their exports, and investments in this sector, leaving aside the industry sector, according to Cavalcante and De Negri (2014). In the same period, there was an increase in employment in the country, due to the growth of production, reaching levels close to full employment, thus, with the exhaustion of available labor, future growth could

[*] Universidade Estadual de Maringá, Centro de Ciências Sociais Aplicadas (UEM/CSA), Departmento de Economia. Av. Colombo 5790, Jd. Universitário, Bloco C-34, Maringá, PR, CEP 87020-900, Brasil. 0000-0001-9605-4895

[†] Universidade Estadual de Maringá, Centro de Ciências Sociais Aplicadas (UEM/CSA), Departmento de Economia. Av. Colombo 5790, Jd. Universitário, Bloco C-34, Maringá, PR, CEP 87020-900, Brasil. 0000-0001-9122-3944

thaisandreiaa@gmail.com mscunha@uem.br

This is an open-access article distributed under the terms of the Creative Commons Attribution License.

Received on Feb 1st, 2019
Final Acceptance on Aug 30th, 2019

no longer support this variable, there being a limitation to demographic increase, due to the aging of the population, according to Bonelli (2014). As well as much discussed in the literature, the level of investment in the country historically has not been able to stimulate desirable economic growth, being insufficient in this objective. Thus, considering the low growth, the depletion of future labor and the insufficient level of investment, it is necessary to look for an alternative as a way to stimulate production. In this way, the focus turns to the study of productivity, as a way to increase the efficiency of production and make it return to having the desired performance.

However, according to Mation (2014), comparing with other countries, it is possible to see that Brazilian productivity performance is not satisfactory, reaching among the countries with the worst productivity when compared to other nations with similar productive structure. It is therefore important to make an analysis in order to identify how certain determinants may be responsible for our low productivity. Thus, it is important to discuss methods that can help the country to follow the growth path of these other countries, among the methods that can help the country in this task is the stimulus of productivity. However, productivity has followed a downward trajectory or stagnation in the country in recent years, so, first, it would be necessary to improve its performance. For this purpose, it is important to verify what can stimulate the improvement in productivity.

Thus, the objective of this study is to make an analysis of some determinants of productivity, verifying the influence on its performance and if these influences can help to understand why the Brazilian productivity has performed so below of what is presented by the economies that have a similar scenario. It is expected that all the determinants analyzed (human capital, innovation, infrastructure, institutional quality, trade openness, and business environment) will have positive effects on productivity. For this purpose, the present study uses the econometric instruments for time series, more specifically the methodology of structural autoregressive vectors (S-VAR), in order to verify improvements in which of the variables would have the greatest effect on productivity performance.

This paper is divided into three sections besides this introduction and the final considerations, in the first section a theoretical and empirical review is made on the relations between productivity and the determinants studied here. The second section describes the methodology used in this study as well as the method of calculating the indicators and the proxies used for each determinant. Finally, in the third section, we present the analysis of the trends of the variables in the period, as well as the results of the model.

2. Theoretical and empirical review

Initially, the determinants of productivity included human capital, which was associated with both labor productivity and total factor productivity. This concept was introduced by Mincer (1958), Schultz (1961), and Becker (1962), who stated that investment in human capital would be investments in education, training in new skills in new jobs, and health, Becker (1962), and Schultz (1961) also included food expenditures on investment in human capital, especially in jobs that required brute force. The authors agreed that these expenditures would tend to lower wages early in life, but

were intended to increase labor earnings over the years. There was agreement that jobs that required more schooling and more experience were also more productive jobs. However, as Becker (1962) stated, considering that a job required specific skills, if the worker quit and sought employment in another activity, as a result, it would not be as productive as the previous one.

Regarding the costs of investing in human capital, Schultz (1961) stated that an apprentice would continue working and learning a new profession until his productivity exceeded the cost of learning, when this happened, he would seek another job that was more convenient, which would leave the employer without recovering his expenses. Therefore, he concluded that training expenses should be paid by employees, that is, the increase in wage earnings would be postponed. However, Becker (1962) also agreed that the costs of training should be paid by employees, but argued this because workers owned property rights over newly acquired skills, which gave them returns on these skills.

With respect to productivity, Schultz (1961), and Becker (1962) affirmed the existence of a wage life cycle. When the worker began his professional life, he would have a low wage, little experience and training, that is, he would have to invest to improve his skills, considering that he would also have low productivity in consequence, as Becker (1962) stated. The more the worker acquired skills, the more his productivity would increase, giving him greater wage gain, enough to compensate for the expenses and the time delayed at the beginning of his professional life.

However, according to Mincer (1958) when the worker reached a certain age his productivity would begin to decrease, which would also lower his wage, and this would occur mainly in activities involving physical effort. So the higher wage during the years of higher productivity would need to be sufficient to supply the wages of the low productivity years both at the beginning and at the end of the wage life cycle. Still on the role of human capital in production, Schultz (1961) related it to productivity through a production function, concluding that during the period from 1900 to 1956, the distance between production and use of inputs increased. This fact suggested that the difference was an increase in productivity. However, as the author pointed out, productivity would be a residual factor, that is, it could not be very large, so Schultz (1961) suggested that human capital would also be responsible for increasing the distance between production and productive inputs.

As with human capital, another highly commented relationship was between productivity and innovation. Griliches's (1979) article, seminal on this subject, using as a tool a production function explained that much of the growth of total factor productivity (TFP) in the United States was due to research and development (R&D) spending, not only those considered at the time of analysis, as well as those from previous years. In fact, Griliches (1979) stated that R&D levels did not always influence TFP, but that this effect would have a lag of three to five years. He also argued that the best approach in the study of this relationship would be through the production function since the econometric approach could have problems that could not be solved at the time.

Still on productivity and innovation, Pakes and Griliches (1984) also related this spending on R&D with the number of patents and found that this relationship also

existed and had an effect on productivity.[1] In order to confirm the existence of the relations, Griliches (1980) carried out a study to verify if a fall in the expenses with research and development had relation or affected the fall of the productivity that occurred in the United States between the decades of 1970 and 1980. Among his results, he concluded that these two falls were related. However, he could not verify the causality between the two movements, besides observing that there was no fall in the TFP, only in the labor productivity. This method of analysis was later adopted by Crepón, Duguet, and Mairesse (1998), who managed to verify the relationship between productivity, research, and innovation at the firm level. Through the study of Griliches (1979), Crepón et al. (1998) managed to sketch a theory relating productivity and innovation, which consisted of some equations, two on research and development, one for innovation and one for productivity, they affirmed that research and development generated innovation that generated productivity, indicating an order of causality between variables. However, Crepón et al. (1998) concluded that research and development did not always generate patents. In summary, it was possible to conclude from these studies that innovation influences productivity.

In turn, infrastructure also contributed greatly to productivity gains. Aschauer (1989), in his seminal paper, showed that infrastructure could be related to productivity, stating that infrastructure in transports would play a primary role in ensuring productivity, just as innovation did. In addition, he considered the fall in investments in infrastructure as one of those responsible for the fall of productivity in the 1970s in the United States, as well as Griliches (1980) stated with spending on R&D. Aschauer (1989) considered investments in infrastructure as government investments, due to the existence of some assets difficult to be offered by the private sector, because they were difficult to price. In addition, the author also sought to verify the role of government in long-run productivity. In the study, he said that the role of government would be very important in the production and concluded that productivity would be moved according to the movements of public capital.

As for Aschauer (1989), Munnel (1990) and Barro (1990) identified that there was a relationship between productivity and government, however, that causality would be from productivity to the definition of the role that the government played in production. Munnel (1990) also focused its analysis on the same period as Aschauer (1989), a period of the 1980s, but the author conducted a regional analysis of the United States stating that states that invested more in public capital obtained greater productivity in the private sector, indicating a correlation between the private and public sectors. And just like Aschauer (1989), Munnel (1990) concluded that investments in basic infrastructure (including transports) would be the ones with the greatest return on private productivity. In analyzing the relationship between public sector and private sector investments, Aschauer (1989), and Barro (1990) concluded that they were complementary, while Munnel (1990) concluded that they would be substitutes.

Another important determinant to explain the behavior and the difference of productivity between different places would be the institutions. North (1990) was one

[1] The methodology was through the inclusion of the variable patents and R&D expenditures in the production function. The period analyzed was mainly from 1968 to 1975 for the industrial firms of the United States.

of the firsts to analyze this relationship. And he said that institutions could be of two kinds, informal (customs, traditions) or formal (laws, property rights). Institutions would be what defined the interactions in a society, so a good institutional environment, formed by both political and economic institutions, would be fundamental to induce an increase in productivity. However, as North (1991) stated, institutions would be intrinsic to each society and would take a long time to change, some even taking a thousand years to change. The author then analyzed the evolution of institutions from the time that production and trade of products were made in the same village when the bourgeoisie emerged. North (1990) observed how the institutional environment evolved, lowering transaction costs, and having a growing impact on the level of productivity.

Also on the institutions, Hall and Jones (1999) resumed the period of colonization and showed that the countries that were colonized by different countries acquired the institutional characteristics of these and that this influenced the institutional environment of the colonized countries until the 20th century. North (1990) further stated that the institutions were intended to ensure the protection of private property rights, and that, if this right were not guaranteed, there would be less incentive for producers to invest in production and that it would be necessary to invest in security expenditures, damaging productivity. In relation to the guarantee of private property rights, Hall and Jones (1999) observed that the institutions were managed by the Government and that at times there could be a divergence in the interests of the latter, so the property right was not fully guaranteed.

With this, the productive differences between certain locations could be explained, because of places with social infrastructure[2] (institutional environment and government policies), more favorable to productive activities would have a higher level of productivity, because there would be less space for corruption, production interferences and impediments to trade. Hall and Jones (1999) concluded that countries with greater social infrastructure had higher labor productivity.Therefore, it was possible to conclude that, although institutions were difficult to change and intrinsic to each society, they would also be responsible for much of the differences in productivity of countries. Considering that better institutions would inhibit practices that deviate from the objective of improving productive activities and guaranteeing the private property rights.

Regarding the relationship between trade openness and productivity, Grossman and Helpman (1990) constructed a theory of growth and trade for two countries considering that the endogenous technological progress resulted from the maximizing profit behavior of the entrepreneurs. The authors related economic growth to trade openness and other international economic conditions. Just as Romer (1990), they divided production between the R&D sector, the goods sector, and the consumer sector, as well as assuming differences for the countries, which would be comparative advantages. In the model, the world was composed of two countries, each engaged in three activities, the production of final goods, the production of a variety of differentiated intermediary goods and research and development.

[2]Measure of institutions used by Hall and Jones (1999).

Grossman and Helpman (1990) stated that the model had constant returns to the scale, however, in the sector of differentiated intermediate goods the existence of increasing returns led to increased productivity, this was done through specialization. Therefore, an increase in the degree of specialization generated gains in technological efficiency. In addition, in order to have greater specialization, innovations in the R&D sector needed to occur. And from this, they considered that the effect of tariffs, export subsidies, and research and development subsidies led to greater specialization, which influenced productivity, and consequently growth. Therefore, it was through the effect of trade openness in the R&D sector that there were improvements in productivity.

Finally, the last relationship to be observed occurs between productivity and the business environment, recently introduced through the study of Djankov, La Porta, de Silanes, and Shleifer (2002). The authors, when conducting a comparative study among countries using regulatory theories, came to the conclusion that the business environment influenced economic growth because, through greater regulation, bureaucracy, procedures, among others, the country could hide some illness, such as corruption, which would negatively impact the growth of the country. Therefore, a greater bureaucratization could discourage companies with considerable productive efficiency to enter the country. They concluded that countries with greater regulatory freedom would tend to grow more and be richer, and the opposite would also be true. Thus, greater regulation and bureaucracy would discourage the opening of productive enterprises and also hide corruption, which would go against the objectives of economic growth, meeting the personal goals of certain groups. In general, considering the literature on the subject, the relations between productivity and its determinants can be represented by Figure 1.

In addition to the causality of the variables for productivity, according to the literature, the productive efficiency also influences innovation. Also, innovation was influenced by all other variables. Being that the institutional quality influences all others too. Finally, evidence of bidirectional causality was found between the business environment and the infrastructure. The same is true of innovation and trade openness.

Considering the importance of the performance of the determinants to the productivity trajectory in theory, it is interesting to see how these relations behaved in different periods, observing if in the course of time they have maintained or if

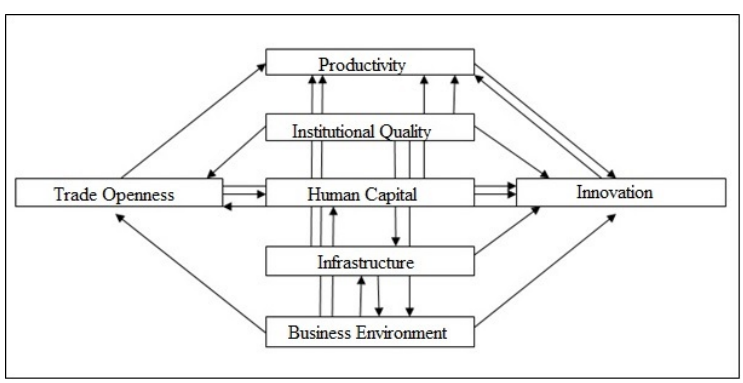


Figure 1. Diagram of Relations between Determinants and Productivity.

there have been changes in their trajectories in the country. Thus, several studies have addressed the relationship between productivity and human capital. Some studies have analyzed how this relationship developed in the second half of the 20th century, such as Ferreira and Veloso (2013), and Barbosa and Pessôa (2008), as well as comparing with the United States, showing how the relationship between human capital and productivity behaved in the period. The studies concluded that Brazil was close to the limit of the possibility of human capital growth and that if this happened it would be necessary to face the real problem in the country, which was the poor quality of education.

Still considering the long run, Jacinto (2015) also verified a long-run relationship between human capital and productivity in the country, in addition to doing an analysis at the level of companies affirming that this relationship was not very divergent between different companies. According to Barbosa, Pessôa, and Veloso (2010), some authors, when measuring human capital, could only take into consideration the years of study and this could jeopardize the analysis. Therefore, when using a methodology that also considered professional experience and income, they concluded that in Brazil, even that human capital increased in the 2000s, this growth was not accompanied by an increase in the earnings of qualified labor, considering that there was an increase in the supply of this labor force, which could have effects on productivity.

Some studies have focused on verifying empirically the positive relationship between innovation and productivity. In Brazil, Catela and Porcile (2013), Steingraber and Gonçalves (2010), Cavalcante, Jacinto, and De Negri (2015), among others, studied this behavior. The studies in Brazil have focused mainly on the industrial sector, observing that it was considered the most innovative sector by Kaldor (1978). However, Lavopa (2011) stated that the innovation process in developing countries would have lower technological sophistication when compared to developed ones, which could explain why the low innovative degree would have impacts on low productivity in developing countries. Therefore, different innovation capacities would be needed in these countries to achieve the same results.

Catela and Porcile (2013), as well as Steingraber and Gonçalves (2010) affirmed that there was no clear causality between innovation and productivity, only that they had a positive relationship. Still on this correlation, Steingraber and Gonçalves (2010), and Silva, da Silveira, Paranhos, Hasenclever, and Miranda (2015) stated that other factors were also included on this relation, besides productivity and innovation. These include social capital, the role of institutions and the business environment, the later affecting negatively, being observed its stagnation in the country.

Among the studies that focused on the relationship between productivity, innovation and investment in research and development are Cavalcante et al. (2015), and Silva et al. (2015). The first ones came to the conclusion that firms that innovated and invested in R&D were more productive, and that when these innovations occurred targeting the world market, gains in productivity were even greater. Silva et al. (2015) studied the relationship between productivity, innovation, and market power, concluding that the greater the market power, the less incentive the company would have to innovate since deficiencies would be absorbed by other sectors.

In turn, the relationship between productivity and infrastructure was also empirically addressed, with infrastructure having great importance in productivity due to the generation of positive externalities, as pointed by Campos, Conceição, and Romminger (2015), and Velloso, Matos, Mendes, and de Freitas (2012), mainly in the transports infrastructure. The authors agreed that when there was poor quality infrastructure there was a generation of negative externalities, through increased costs, rigidity and inefficiency throughout the economy, considering that there would be a need to use transportation both to move inputs and production, which could also cause negative impacts even on foreign trade. On the other hand, when there was a good quality infrastructure, returns to the economy improved their efficiency, since, for example, through good roads and railways, companies could carry out their productions far from the center of their consumers, being able to worry about install in a place that would provide better labor force, technological diffusion, among others.

Campos et al. (2015), Velloso et al. (2012), and Schettini and Azzoni (2015) analyzed the role of government and private companies in providing adequate infrastructure. The authors noted that both types of investment were not substitutes, but complementary, that is, government investment did not discourage private companies from competing. Based on this assertion, Mussolini and Teles (2010) studied the ratio between public and private capital as a measure of the degree of infrastructure and its relation to productivity for the second half of the twentieth century in Brazil, confirming that there was a long-run relationship between infrastructure and total factor productivity.

There are also studies that aimed to analyze the role of regional infrastructure on productivity, among them were Benitez (1999) and, more recently, Schettini and Azzoni (2015). Thus, like the other studies, they showed a positive relation between infrastructure and productivity, and Schettini and Azzoni (2015) focused their study on the industrial sector. In both studies, they confirmed that there was a greater impact of infrastructure on productivity in the Southeast region, which was explained by the greater degree of infrastructure in this region.

Regarding the relationship between productivity and the institutional environment, for Gonçalves (2008), countries would need to maintain institutions that were efficient in defending private property rights, so that producers and entrepreneurs would be encouraged to invest in production. In addition, efficient institutions would also generate lower transaction costs.

As institutions take a long time to change, some papers have sought to relate their performance to productivity in Brazil in the twentieth century. Among them were Alston, Mueller, Melo, and Pereira (2010), and Yano and Monteiro (2008), the first made an analysis from 1930 until the most recent periods, Governments Fernando Henrique Cardoso and Lula. While the second related some institutional reforms in the 1990s with productivity, reaching the conclusion that greater trade openness and financial reform had a positive effect on productivity. Some other papers also related institutions to productivity through other relationships, among them were Steingraber and Gonçalves (2010), and Dias and Tebaldi (2012), the former related the institutions to innovation, and thus allowed it to affect productivity. The latter showed that institutions influenced human capital, and this, in turn, influenced productivity.

Several studies in Brazil have tried to verify how the trade openness affected productivity performance, mainly the industrial one. Among them were Rossi and Ferreira (1999), Ferreira and Rossi (2003), Ferreira and Guillén (2004), and Fraga (2016), among others. In considering the impact of trade openness on productivity, Rossi and Ferreira (1999) analyzed the role of trade openness in both labor productivity and total factor productivity in the Brazilian manufacturing industry from 1985 to 1997. They affirmed that until 1990 there was stagnation of productivity and that from that year until 1997 there was significant growth.

Rossi and Ferreira (1999) also stated that trade openness had a significant impact on productive efficiency, and concluded that trade barriers caused productivity rates to fall, that is, more economically open countries had more stimulus to grow, however, trade barriers measures could be adopted with the aim of protecting industry from the countries. Ferreira and Rossi (2003) verified the relationship of the positive effects of international trade on the productivity of Brazilian industry from 1988 to 1990. Among the results, they found that trade barriers had decreased and that this led to increased productivity. Ferreira and Guillén (2004) also studied the relationship between industrial productivity and trade openness and concluded that there was an increase in average productivity in the industry after reductions in trade barriers.

Fraga (2016) analyzed the relationship between foreign direct investment, labor productivity, and total factor productivity and trade openness from 1996 to 2007, considering twenty-two sectors of the manufacturing industry through a dynamic panel analysis. Among the results, it was concluded that trade openness influenced productivity, in addition to the import penetration coefficient. Considering TFP, the trade openness was one of the variables that influenced it the most. Therefore, what was possible to conclude is that given the evidence presented by Brazil, trade openness had positive effects on improving Brazilian productivity, especially in the manufacturing industry.

Regarding the business environment and productivity, in countries where there is a precarious business environment, productivity performance may suffer. Some papers have emphasized how the ease of opening a business and the very ease of maintaining this business have affected labor productivity, however, there are still few studies analyzing this relationship. Mation (2014), and Cavalcante et al. (2015) analyzed the Brazilian business environment and its relationship with productivity, while Bah and Fang (2011) studied the African continent and Diagne (2013) studied Senegal. What all these studies had in common was that they were made in places where the business environment was not desirable.

Cavalcante et al. (2015), and Diagne (2013) related productivity to the business environment through investment. Diagne (2013) concluded that if there was an improvement in this environment, in addition to growth in TFP, there would also be a 79% product and a 94% investment growth. In addition, Mation (2014), and Bah and Fang (2011) also agreed that improvements in the business environment could have positive effects on productivity. Mation (2014) even concluded that most of the poor countries with poor business environment indexes had a positive evolution in the period, however, Brazil dissociated from this movement, leaving its business environment practically stagnant, which did not contribute to improving productivity

performance. Although there was a strong correlation between the variables, this was mainly due to factors invariant in time.

Thus the empirical relations to Brazil between productivity and its determinants are in line with what is expected in theory. Therefore, it was assumed that improving the performance of these determinants could improve productivity performance and thus contribute to continued economic growth in the long run. Considering these facts, this paper seeks to verify how these variables, together, affect productivity in Brazil in the recent period. That is, the assumptions made are that the variables human capital, innovation, infrastructure, institutional quality, trade openness, and business environment all positively affect labor productivity. And the objective is to verify which determinant have the greatest impact on productivity performance.

3. Methodological Procedures

3.1 Database

The empirical analysis based on the use of the time series econometric technique seeks to analyze the variables that, considering the theoretical and empirical literature, affect the performance of labor productivity, considered as a measure of productive efficiency. The objective was to identify which determinant variable most influenced productivity in the period. On the basis of its identification, measures can be adopted for its growth, which also seeks to boost productivity growth, and consequently economic growth. This study used as determinants the variables suggested by De Negri and Cavalcante (2014), namely, human capital, innovation, infrastructure, institutional quality, and business environment, plus trade openness.

GDP was used as a production measure, being deflated by the implicit GDP deflator, taken from the Contas Nacionais Trimestrais (IBGE, n.d.). Regarding the income information, occupation status, the weight of the person, calculated age and number of hours worked, used to measure the average number of hours worked in the economy per quarter, they were taken from the Pesquisa Mensal de Emprego (PME, n.d.). All these variables were used to construct the indicator of labor productivity.

The variables average years of study, the weight of the person, age, income, and occupation condition were used to calculate the institutional quality, human capital, and business environment indexes, and were taken from the Pesquisa Mensal de Emprego (PME, n.d.). In relation to the variable electric power generation, it was obtained the proxy for the infrastructure variable from Ipeadata (n.d.). Regarding exports, imports and GDP, the variable of trade openness was obtained, and, finally, GDP in dollars and FDI were used to measure the innovation index, and the variables were taken from the Banco Central do Brasil (BCB, n.d.) and Contas Nacionais Trimestrais (IBGE, n.d.).

3.2 Methods

3.2.1 Measurement of Variables

The analysis was made for the period from 2004 to 2014, being carried out by quarters. Therefore, it was necessary to calculate the proxies for the unit of time established. First, the methodology used for the calculation of labor productivity followed the method of

Barbosa and Pessôa (2014). Therefore, the methodology obtained was:

$$LP_t = \frac{Y_t}{L_t}, \tag{1}$$

in which t refers to each quarter, Y_t refers to total production, and L_t refers to the number of total hours worked in the economy. The real production was obtained using the implicit GDP deflator based on the year 2010. The measure of labor used in the estimation was based on the methodology of Barbosa and Pessôa (2014):

$$L_{i,j} = \sum_{\substack{i=1 \\ j=1}}^{N} p_{i,j} WH_{i,j}, \tag{2}$$

where $L_{i,j}$ is the average number of hours worked in the week of all workers, $WH_{i,j}$ is the average number of hours worked per worker, and $p_{i,j}$ is the weight of the person in the sample. The average number of hours for the month was calculated by multiplying it by the number of weeks per month and then summed to complete the quarter. Regarding the weight of the person, the weight of the last month referring to each quarter was used.

The measurement of human capital followed the methodology of Caselli (2005), being estimated through the function

$$HC_{i,j} = e_{i,j}^{\varphi_{i,j}(s_{i,j})}, \tag{3}$$

with $HC_{i,j}$ being the stock of human capital per person, $\varphi_{i,j}$ representing the returns to education and $s_{i,j}$ the average schooling. The estimation of returns to education followed the wage equation of Mincer (1974),[3] in which

$$\ln\left(w_{i,j}\right) = \beta_0 + \beta_1 s_{i,j} + \beta_2 exp_{i,j} + \beta_3 exp_{i,j}^2 + \varepsilon_{i,j}, \tag{4}$$

where $\ln\left(w_{i,j}\right)$ is the natural logarithm of workers' income and $exp_{i,j}$ is equal to experience. The return to education assumed the value of β_1 in the income equation. Age above 10 years was considered as the minimum age for the estimation of total average hours worked and human capital, according to IBGE (n.d.). With regard to the institutional quality index, we chose to use the methodology proposed by Dias and Tebaldi (2012):

$$inst = \frac{\varphi\beta\gamma}{r}, \tag{5}$$

in that $\varphi\beta\gamma$ referred to people with post-secondary education, therefore, above 11 years of schooling, and r referred to uneducated people, individuals over 25 were considered in the estimation. This variable was used because, according to Dias and Tebaldi (2012), in countries where there is better institutional quality, people have more incentives to invest in education and human capital, since in the future they will obtain a return for these studies. Therefore, the higher the ratio between people with higher education and uneducated, the better the performance of institutions. Both human capital and

[3]The calculation of the income equation was done using Stata software.

institutional quality obtained monthly results, so an average was made between the months of each quarter in order to present a quarterly result.

Regarding the business environment, Fontes and Pero (2012) affirmed that a good business environment would be related to formalization conditions in the labor market, and Djankov et al. (2002) stated that the higher cost and time spent opening a new business would be associated with an increase in informality. In addition, in the Doing Business Report, World Bank (n.d.), which measures the business environment for several countries, has an index that records labor market regulation. Therefore, the formality in the labor market was treated as a proxy for the business environment, following the methodology of Barbosa and Moura (2015),[4] in which

$$BUS_t = \frac{Formality_t}{Formality_t + Informality_t}, \tag{6}$$

where *BUS* means business environment. Considering the proxy for infrastructure, the sum of the generation of thermal, conventional, nuclear thermal and emergency thermal power was used, then, as the variables were presented per month, these were added in order to complete the quarter. In relation to the trade openness index, according to Magalhães, Branco, and Cavalcanti (2007), the ratio between the sum of exports and imports and GDP was used:

$$TRAD = \frac{X + M}{GDP}, \tag{7}$$

where *TRAD* means trade openness, X refers to exports and M to imports. Finally, the innovation index followed the methodology of Araujo, Araujo, Durlo, and Santos (2015), the ratio between foreign direct investment inflows and GDP:

$$INOV = \frac{FDI}{GDP}, \tag{8}$$

with *INOV* referring to the index of innovation, and *FDI* referring to foreign direct investment. Regarding the variable innovation, was obtained the sum of the months to compose the index of the quarter.

3.2.2 Methodology

Before entering the econometric analysis, first, the study sought to perform a growth decomposition to verify the importance of productivity in terms of economic growth in Brazil, in the period analyzed. Thus, growth decomposition was also performed to measure how labor productivity measured by the number of average hours worked contributed to the total production, following Barbosa and Pessôa (2014), using this equation:

$$\frac{1}{N}\ln\left(\frac{GDP_{t+N}}{GDP_t}\right) = \frac{1}{N}\ln\left(\frac{LP_{t+N}}{LP_t}\right) + \frac{1}{N}\ln\left(\frac{WH_{t+N}}{WH_t}\right) + \frac{1}{N}\ln\left(\frac{OP_{t+N}}{OP_t}\right), \tag{9}$$

in which *WH* is the worked hours or the ratio between total hours worked and people occupied, with $N = 1, \ldots, 44$, the number of observations or number of quarters.

[4] The formality proxy was used to measure the business environment due to the unavailability of monthly data for Brazil.

Then, regarding econometric analysis, time series econometric techniques were adopted, as suggested by Enders (2010), and it is considered as a unit of time the quarter in the period from 2004 to 2014 in Brazil, therefore, totaled 44 observations. First, it was necessary to verify if the analyzed variables were stationary, being analyzed by the unit root test of Augmented Dickey–Fuller (ADF), Dickey–Fuller GLS, Phillips–Perron (PP) e Kwiatkowski–Phillips–Schmidt–Shin (KPSS). As the variables were stationary at the level, the methodology of structural autoregressive vectors (S-VAR) would be used. However, if the variables presented stationarity in the differences, it would be necessary to test the existence of cointegration, and being detected the cointegration, the model would be estimated through the methodology of Vector Error Correction (VEC), however, not being detected the cointegration, the methodology would be of Structural Autoregressive Vectors (S-VAR) in the differences. The stationarity of the analyzed series is necessary so that spurious regression results cannot be generated, according to Enders (2010), so if variables with roots are presented, they must be differentiated until they become stationary. The estimated model, according to the theory, uses the following order of exogeneity:

$$lprod = \alpha_1 linov + \alpha_2 ltrad + \alpha_3 lbus + \alpha_4 lhc + \alpha_5 linfr + \alpha_6 linst + \varepsilon\,, \qquad (10)$$

in that *lprod* is the logarithm of labor productivity, *linov* is the logarithm of innovation, *ltrad* is the logarithm of the trade openness, *lbus* is the logarithm of the business environment, *linfr* is the logarithm of the infrastructure, *lhc* is the logarithm of human capital and *linst* is the logarithm of institutional quality. It was decided to estimate the model in logarithms to be analyzed in elasticities and the order of presentation of the variables was also made considering the exogeneity of the variables found according to the literature review. It is expected that all variables will have a positive impact on productivity. The S-VAR methodology denotes y as a vector $(n\times 1)$ containing the value of n variables, in the case, 7 variables, assumed in the period. According to Hamilton (1994), the dynamics of y is presumably governed by a Gaussian autoregressive vector of order p:

$$y_t = c + \Phi_1 y_{t-1} + \Phi_2 y_{t-2} + \cdots + \Phi_p y_{t-p} + \varepsilon_t\,. \qquad (11)$$

The methodology employed in the study was the S-VAR, considering the results of the unit root tests results in the variables being stationary in level, and if any variable had root, the variable in difference would be used. The S-VAR is a methodology considered as atheoretical since it does not distinguish between endogenous or exogenous variables in the estimation, which could lead to bilateral causality. Therefore the importance of defining the number of lags to be used, since the ideal would be to use few lags in the model so that many degrees of freedom would not be consumed or there would be multicollinearity or specification bias, according to Enders (2010).

Therefore, after the estimation of S-VAR, autocorrelation, heteroscedasticity and normality tests were performed in order to verify if the errors were white noise, a necessary condition for the model to present consistent results. In addition, the lag length criteria were also applied in order to specify the best lag to be used in the model. After the specification of the lag criterion, the stability of the S-VAR was verified. Finally, we obtained the results of the estimation, the impulse response function and

the variance decomposition, demonstrating the impact of each independent variable on the dependent variable over time when exposed to shocks.

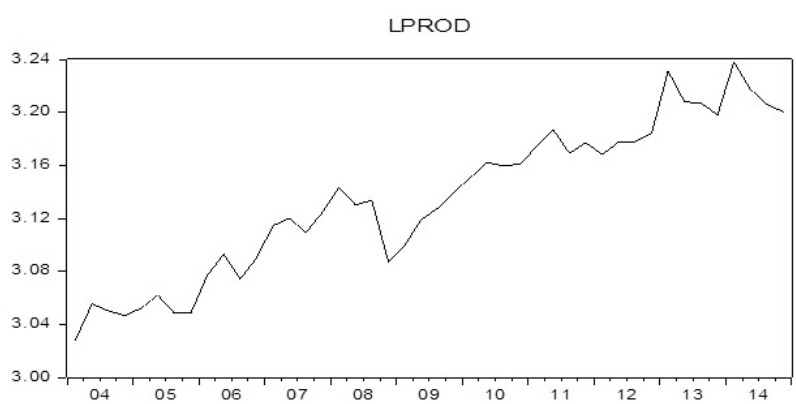
4. Results and Discussions

In analyzing the model, first of all, it is interesting to observe the productivity performance in the period. Figure 2 presents the evolution of the variable. The trend was growth in the period, the same performance obtained by Bonelli (2014), De Negri and Cavalcante (2014), Barbosa and Pessôa (2014), Bonelli and Bacha (2013), among others.

The performance of the series of the determinants was verified in Figure 3, and it was possible to observe that all the determinants presented a trajectory of growth in the period, as well as the productivity. The variables that obtained the greatest growth trajectory were stock of human capital and institutional quality, which are important not only for productivity growth but also for improvement in several other indicators of the country, such as economic growth and development. They were also the variables that were less impacted with the 2008 Crisis.

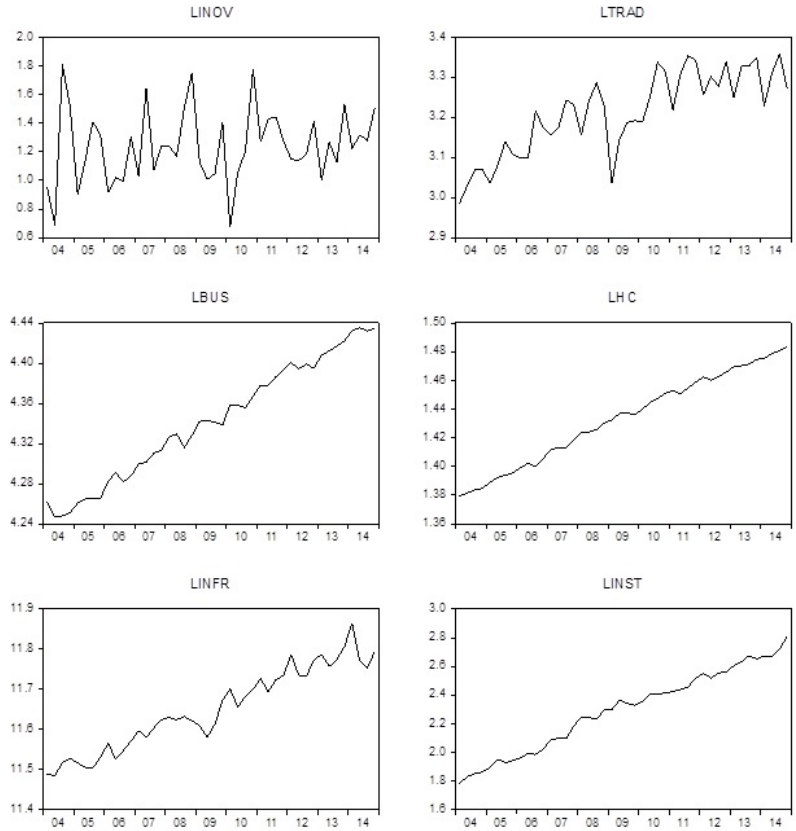
Among the variables that obtained greater volatility, there were found the logarithm of innovation and the logarithm of trade openness. In the series of trade openness, it is possible to identify a certain cycle of growth and fall of the indicator, being the exception in the period 2008–2009, which may have been due to the Economic Crisis of 2008, since it is a variable highly influenced by external movements to the country. The variable innovation obtained a significant oscillation during the analyzed period, not going unnoticed in 2008, however, on average, its growth trend was lower compared to the other determinants. The variables business environment and infrastructure, as well as human capital and institutions, tended to grow in the period, but more sustained than the last ones.

Following, Table 1 shows the contributions of the factors for Brazilian economic growth during the period from 2004 to 2014. First, it can be seen that economic growth was positive throughout the period, however, it has tended to fall over time. In addition, it can be verified that the contribution of labor productivity to growth during the period



Source: Own elaboration from the software Eviews 7 (2017).

Figure 2. Performance of the Logarithm of Brazilian Labor Productivity 2004–2014 (per quarter).



Source: Own elaboration from the software Eviews 7 (2017).

Figure 3. Graphical Analysis of the Independent Variables 2004–2014 (per quarter).

Table 1. Growth Decomposition 2004–2014 (% per quarter).

Period	GDP	LP	WH	OP
2004Q1–2004Q4	1.92	0.46 (23.87)	0.27 (14.32)	1.19 (61.80)
2005Q1–2005Q4	1.43	−0.10 (-6.83)	0.72 (50.35)	0.81 (56.49)
2006Q1–2006Q4	1.55	0.33 (21.38)	0.25 (15.97)	0.97 (62.65)
2007Q1–2007Q4	1.89	0.25 (13.17)	0.73 (38.68)	0.91 (48.15)
2008Q1–2008Q4	0.65	−1.40 (−214.89)	1.16 (177.11)	0.90 (137.77)
2009Q1–2009Q4	2.56	1.00 (39.14)	0.53 (20.57)	1.03 (40.29)
2010Q1–2010Q4	1.74	0.26 (14.77)	0.67 (38.59)	0.81 (46.63)
2011Q1–2011Q4	1.11	0.08 (7.13)	0.52 (47.02)	0.51 (45.86)
2012Q1–2012Q4	1.3	0.40 (30.50)	0.03 (2.06)	0.88 (67.44)
2013Q1–2013Q4	1.26	−0.83 (−65.89)	1.64 (130.04)	0.45 (35.85)
2014Q1–2014Q4	0.32	−0.94 (−294.08)	0.94 (292.98)	0.32 (101.10)
2004Q1–2014Q4	0.91	0.39 (43.23)	−0.01 (−0.91)	0.52 (57.69)

Note: Between parentheses, there are the percentage contributions of each input factor to economic growth, the ratio between the growth of the factor of production and the growth of production.

Source: Own elaboration based on the data of IBGE (n.d.), PME (n.d.), and Ipeadata (n.d.).

had some changes, and in some years became negative, including the last two years of the analysis. In relation to the working hours and the occupied population, it is verified that there was a positive contribution during the whole period. Thus, it is verified that the Brazilian economic growth reached during the period of analysis was not based on productivity gains, that is, there is room for improvements in productivity to lead to increases in the growth of Brazilian production.

After verifying the trends of the variables, the results of the stationarity tests are presented in Table 2, and more than one stationarity test was performed due to differences in its parameters. It was concluded that all variables were stationary in level, with the exception of human capital. Thus, the variable *lhc* was differentiated, allowing for the adoption of the structural Autoregressive Vectors methodology, which requires the stationarity of the series.

As estimated by the S-VAR model, the Lag Length Criteria test suggested the use of 3 lags by the Akaike criterion and 1 lag by the other criteria. We chose to use 1 lag in the model due to the results of the tests, also due to the limited number of observations obtained in the period, and with this option, no autocorrelation or heteroscedasticity was detected. In addition, the residues were considered normal. Thus, it was possible to verify the results of the estimation of S-VAR in Table 3.

First, with respect to the results, it can be verified that, with the exception of innovation, all other determinants contributed positively to labor productivity in the analyzed period. In addition, it was verified that among the determinants, considering the long run, according to the model, the variables trade openness, infrastructure, and institutional quality not only presented positive parameters but were also statistically significant for the estimated model. Finally, among the determinants analyzed, the one that contributed most in terms of elasticity to productivity was the institutional quality.

In the following, the results obtained from the analysis of the impulse response function are presented in Figure 4. As with the results of the econometric estimation, it is verified that innovation was the only determinant that presented a negative response of the productivity to the shocks caused in the innovation.

In the other variables, it is seen that there is a positive response of productivity to shocks occurring, with the greatest shock occurring through infrastructure, followed by business environment, institutional quality and human capital. However, it is also important to remember that only in two of these variables there was a long-run statistical significance. Thus, both institutional quality and infrastructure provide positive impacts on the performance of long-run labor productivity.

The decomposition of the variance shows how productivity decomposes itself in terms of the analyzed variables, it is possible to verify its results in Table 4. It is interesting to note that in the very short run the productivity variable is fully explained by itself, and the other variables were not representative. However, as the periods progressed, productivity began to depend on other determinants, although not much, because after ten quarters it is seen that it was still responsible for 76.58% of its variations.

Considering the short period of two quarters, not counting productivity itself, the variable that most caused variations was infrastructure, with 8.15%, followed by innovation with 2.97%, but it is necessary to remember that according to the

Table 2. Results of the Unit Root Tests.

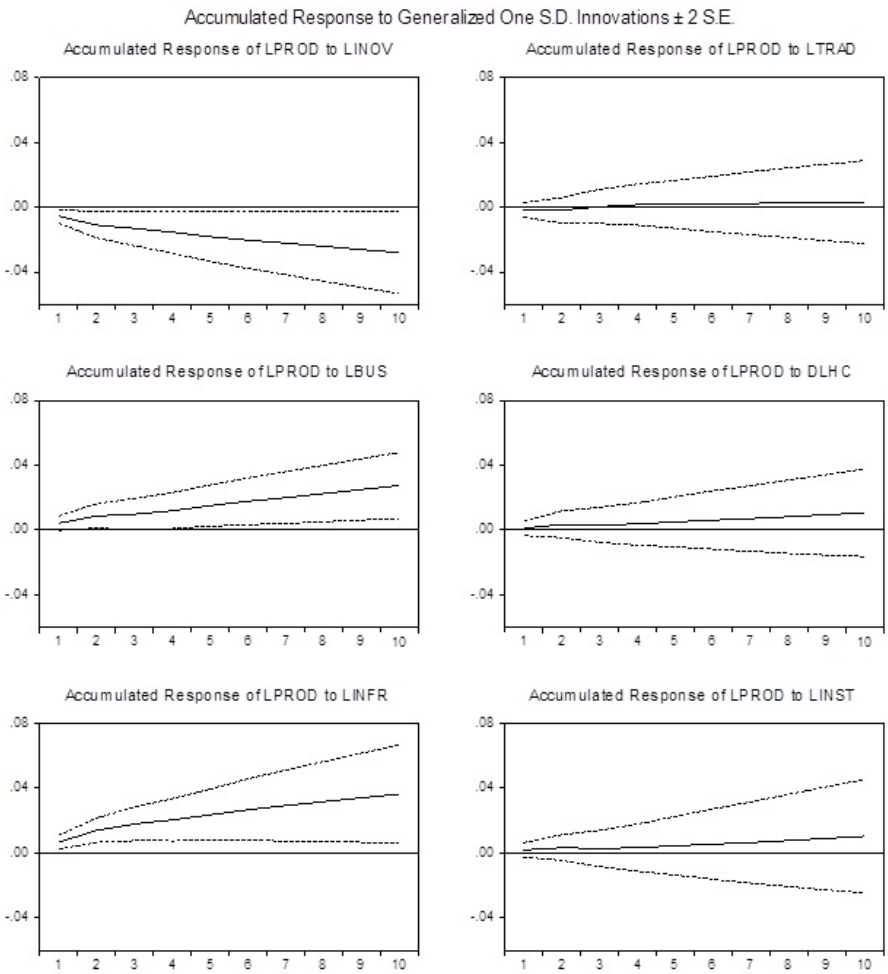
Variables	Statistic t	1% Critic Value	5% Critic Value	10% Critic Value
ADF – Level				
lprod	−3.9956	−4.186481	−3.51809	−3.189732
linov	−6.567211	−4.186481	−3.51809	−3.189732
ltrad	−2.551058	−4.211868	−3.529758	−3.196411
lbus	−5.694939	−4.192337	−3.520787	−3.191277
lhc	−2.978318	−4.186481	−3.51809	−3.189732
linfr	−3.353767	−4.211868	−3.529758	−3.196411
linst	−3.282199	−4.186481	−3.51809	−3.189732
ADF – 1 Difference				
ltrad	−3.090306	−4.211868	−3.529758	−3.196411
lhc	−7.359523	−4.205004	−3.526609	−3.194611
ADF – 2 Difference				
ltrad	−13.61044	−4.211868	−3.529758	−3.196411
GLS – Level				
lprod	−4.006257	−3.77	−3.19	−2.89
linov	−6.39185	−3.77	−3.19	−2.89
ltrad	−2.107448	−3.77	−3.19	−2.89
lbus	−4.130388	−3.77	−3.19	−2.89
lhc	−3.070016	−3.77	−3.19	−2.89
linfr	−3.127182	−3.77	−3.19	−2.89
linst	−3.217647	−3.77	−3.19	−2.89
GLS – 1 Difference				
ltrad	−2.640952	−3.77	−3.19	−2.89
GLS – 2 Difference				
ltrad	−1.708917	−3.77	−3.19	−2.89
PP – Level				
lprod	−3.976022	−4.186481	−3.51809	−3.189732
linov	−9.054699	−4.186481	−3.51809	−3.189732
ltrad	−4.684137	−4.186481	−3.51809	−3.189732
lbus	−6.31507	−4.186481	−3.51809	−3.189732
lhc	−2.876072	−4.186481	−3.51809	−3.189732
linfr	−5.128272	−4.186481	−3.51809	−3.189732
linst	−3.192639	−4.186481	−3.51809	−3.189732
PP – 1 Difference				
lhc	−12.51271	−4.192337	−3.520787	−3.191277
KPSS – Level				
lprod	0.073056	0.216	0.146	0.119
linov	0.201673	0.216	0.146	0.119
ltrad	0.124716	0.216	0.146	0.119
lbus	0.071478	0.216	0.146	0.119
lhc	0.223768	0.216	0.146	0.119
linfr	0.075149	0.216	0.146	0.119
linst	0.1583	0.216	0.146	0.119
KPSS – 1 Difference				
lhc	0.15985	0.216	0.146	0.119

Source: Own elaboration from the software Eviews 7 (2017).

Table 3. Estimates for the Model, 2004–2014.

Variables	Coefficients	Standard-error	Statistic z	Prob.
lprod	0.010426	0.001138	9.165151	0.000000
linov	−0.000017	0.001609	−0.010580	0.991600
ltrad	0.007211	0.001791	4.026215	0.000100
lbus	0.000764	0.001958	0.390428	0.696200
lhc	0.000938	0.001962	0.478258	0.632500
linfr	0.033524	0.004152	8.073896	0.000000
linst	0.346630	0.038223	9.068600	0.000000

Source: Own elaboration from the software Eviews 7 (2017).



Source: Own elaboration from the software Eviews 7 (2017).

Figure 4. Impulse-Response Function.

Table 4. Decomposition of Variance.

Period	S.E.	LPROD	LINOV	LTRAD	LBUS	DLHC	LINFR	LINST
1	0.014684	100	0	0	0	0	0	0
2	0.017424	86.83745	2.972981	0.182771	1.625818	0.226698	8.153096	0.001189
3	0.018285	82.11693	2.867828	2.263976	2.016969	0.551795	10.12671	0.055791
4	0.019003	81.30535	2.854395	2.926662	2.751554	0.579937	9.507707	0.074395
5	0.019721	80.54826	3.012158	2.813462	3.777733	0.540428	9.225496	0.082467
6	0.02024	79.41267	3.032252	2.767676	4.636341	0.519634	9.505024	0.126398
7	0.020659	78.54303	3.024177	2.823037	5.338405	0.504163	9.558958	0.208226
8	0.021069	77.87828	3.056118	2.828229	6.014356	0.484851	9.447907	0.290264
9	0.021461	77.22491	3.100408	2.791249	6.671733	0.467592	9.374984	0.369123
10	0.021817	76.58262	3.130257	2.759612	7.276473	0.452794	9.344648	0.453594
Cholesky Order: LPROD LINOV LTRAD LBUS DLHC LINFR LINST								

Source: Own elaboration from the software Eviews 7 (2017).

previous analysis, this contribution is negative, moreover, initially, the determinant that contributed least was institutional quality. Within ten quarters, infrastructure continued to be the determinant that caused most changes in productivity, followed by the business environment, innovation, trade openness, human capital and institutional quality, which remained the determinant that caused the least changes in productivity. This may happen due to the resilience of institutions to change in the short run. Therefore, both short-run and long-run policies that aim to stimulate productivity could stimulate improvements in infrastructure for this purpose. When verifying how much each determinant responds for the variations in the productivity, it was possible to verify some productivity rigidity in the short run, that is, the majority of the explanations of its variances were explained by itself. This left little space for the performance of the other variables, at least in a short period, as analyzed by the model. Therefore, when comparing the results of Table 4 with the increasing productivity performance in Figure 1 and the increasing performance of the determinants in Figure 3, it was possible to verify that, although the determinants are growing in the period, their effects have not yet been enough so that productivity has sufficient effect to contribute positively and sustainably to long-run growth.

Therefore, according to the results of the econometric analysis together with the results described in the empirical evidence, it was verified that in fact, the determinant variables analyzed influence the Brazilian productivity performance in the period. The variable that presented the greatest influence on productivity was the infrastructure since it has great importance for generating positive externalities, as Campos et al. (2015), and Velloso et al. (2012) pointed out, mainly highlighting the transports infrastructure. This is because if there is poor quality infrastructure there is a generation of negative externalities, through increased costs, rigidity, and inefficiency throughout the economy, considering that it would be necessary to use transport both to move inputs and production, which could also cause negative impacts even in foreign trade. Thus, good quality infrastructure generates returns to the economy that improves its

efficiency, since companies could conduct their productions far from the center of their consumers, being able to worry about settling in a place that would provide a better labor force, technological diffusion, among others.

5. Final Considerations

The objective of the present study was to verify the impact of some determinants, together, on the performance of Brazilian labor productivity in the period from 2004 to 2014, considering the trend of low growth that this variable has been suffering in the last decades and its importance for the country's economic growth. What has been verified is that the literature review, both theoretical and empirical, recognizes the importance of the impact of these selected determinants on productivity performance.

From the analysis of the trend of these variables in logarithms in the period covered, it was verified that the determinants had a tendency of growth in the period, some of which grew more than the others. It was verified that human capital and institutions were the determinants that obtained the highest increase, and that were less affected by the Crisis of 2008, whereas the innovation and the trade openness were the determinants that had more oscillation during the period, being that the first had more modest growth compared to the other determinants, despite the oscillations, and the last was the determinant that was most affected by the 2008 Crisis.

Then, when analyzing the impacts of the determinants together on productivity, it was possible to verify that, although these determinants increased during the period, this was not enough for productivity to grow uniformly and positively, and sustainably influence economic growth. Therefore, even greater improvements are needed with a longer time horizon in the determinants so that they can positively influence productivity, being that this is a variable that in the short term is more influenced by its own past behavior, that is, the low efficient past performance. Thus, it is necessary to aim for the long term to achieve changes in productivity behavior. Regarding the effects of the determinants analyzed, through the analysis of time series, it was verified that improvements in infrastructure, but also in institutional quality, tend to have a greater impact on productivity in both the short and long periods.

Therefore, it would be important to consider the impacts of exogenous determinants on the production process for productivity analysis. In doing so, it was found that infrastructure had a greater effect on productivity performance, however, it must be remembered that the analysis was based on the short run, and the effect of the determinants was low, accounting for less than 25% of the variances productivity. Thus, it is concluded that a longer period would be necessary for the variables to influence and stimulate productivity growth, given its resilience in the short run.

References

Alston, L. J., Mueller, B., Melo, M. A., & Pereira, C. (2010). *The political economy of productivity in Brazil* (IDB Working Paper No. IDP-WP-104). Washington, DC: Inter-American Development Bank (IDB). http://hdl.handle.net/11319/1123

Araujo, E. L., Araujo, E. C., Durlo, R. M., & Santos, S. A., Jr. (2015, Jun). Os determinantes do crescimento econômico mundial: Algumas evidências para o período 1994–2012. In *18º Encontro de Economia da Região Sul (ANPEC-SUL)*, Porto Alegre.

Aschauer, D. A. (1989). Is public expenditure productive? *Journal of Monetary Economics*, *23*, 177–200. http://dx.doi.org/10.1016/0304-3932(89)90047-0

Bah, E.-h., & Fang, L. (2011, November). *Impact of the business environment on output and productivity in Africa* (Working Paper No. 2011-14). Federal Reserve Bank of Atlanta. https://www.frbatlanta.org/research/publications/wp/2011/14

Barbosa, F. H., Filho, & Moura, R. L. (2015). Evolução recente da informalidade do emprego no Brasil: Uma análise segundo as características da oferta de trabalho e o setor. *Pesquisa e Planejamento Econômico*, *45*(1), 101–123. http://repositorio.ipea.gov.br/handle/11058/4130

Barbosa, F. H., Filho, & Pessôa, S. A. (2008). Retorno da educação no Brasil. *Pesquisa e Planejamento Econômico*, *38*(1), 97–125. http://repositorio.ipea.gov.br/handle/11058/3357

Barbosa, F. H., Filho, & Pessôa, S. A. (2014). Pessoal ocupado e jornada de trabalho: Uma releitura da evolução da produtividade no Brasil. *Revista Brasileira de Economia*, *68*(2), 149–169. http://dx.doi.org/10.1590/S0034-71402014000200001

Barbosa, F. H., Filho, Pessôa, S. A., & Veloso, F. A. (2010). Evolução da produtividade total dos fatores na economia brasileira com Ênfase no capital humano, 1992–2007. *Revista Brasileira de Economia*, *64*(2), 91–113. http://dx.doi.org/10.1590/S0034-71402010000200002

Barro, R. J. (1990). Government spending in a simple model of endogeneous growth. *The Journal of Political Economy*, *98*(5), 103–125. http://dx.doi.org/10.1086/261726

BCB – Banco do Brasil. (n.d.). *Time Series Management System – v2.1: Public module.* Retrieved Jan 26, 2017, from https://www3.bcb.gov.br/sgspub/

Becker, G. S. (1962). Investment in human capital: A theoretical analysis. *Journal of Political Economy*, *70*(5), 9–49. http://dx.doi.org/10.1086/258724

Benitez, R. M. (1999). A infra-estrutura, sua relação com a produtividade total dos fatores e seu reflexo sobre o produto. *Planejamento e Políticas Públicas*, *19*, 275–306. https://www.ipea.gov.br/ppp/index.php/PPP/article/view/95/0

Bonelli, R. (2014). Produtividade e armadilha do lento crescimento. In F. De Negri & L. R. Cavalcante (Eds.), *Produtividade no Brasil: Desempenho e determinantes* (Vol. 1, pp. 111–142). Brasília: IPEA:ABDI. https://www.ipea.gov.br/portal/index.php?option=com_content&id=23986

Bonelli, R., & Bacha, E. (2013). Crescimento brasileiro revisitado. In F. A. Veloso, P. C. Ferreira, F. Giambiagi, & S. D. A. Pessôa (Eds.), *Desenvolvimento econômico: Uma perspectiva brasileira.* Rio de Janeiro: Campus.

Campos, C. A. S., Neto, Conceição, J. C. P. R., & Romminger, A. E. (2015). Impacto da infraestrutura de transportes sobre o desenvolvimento e a produtividade no Brasil. In F. De Negri & R. Cavalcante (Eds.), *Produtividade no Brasil: Desempenho e determinantes* (Vol. 2, pp. 361–390). Brasília: IPEA:ABDI. https://www.ipea.gov.br/portal/index.php?option=com_content&view=article&id=26104

Caselli, F. (2005). Accounting for cross-country income differences. In P. Aghion & S. Durlauf (Eds.), *Handbook of economic growth* (Vol. 1, pp. 679–741). Elsevier.

Catela, E. Y. S., & Porcile, G. (2013, Dec 10–13). Produtividade setorial da indústria brasileira: Uma análise dos determinantes a partir de regressão quantílica para painel de dados com efeitos fixos. In *41º Encontro Nacional de Economia (ANPEC)*, Foz do Iguaçú. http://www.anpec.org.br/encontro/2013/files_I/i9-46829124707dd1f1d5183193db307929.pdf

Cavalcante, L. R., & De Negri, F. (2014). Evolução recente dos indicadores de produtividade no Brasil. In F. De Negri & L. R. Cavalcante (Eds.), *Produtividade no Brasil: Desempenho e determinantes* (Vol. 1, pp. 143–171). Brasília: IPEA:ABDI. https://www.ipea.gov.br/portal/index.php?option=com_content&id=23986

Cavalcante, L. R., Jacinto, P. A., & De Negri, F. (2015). P&D, inovação e produtividade na indústria brasileira. In F. De Negri & R. Cavalcante (Eds.), *Produtividade no Brasil: Desempenho e determinantes* (Vol. 2, pp. 43–68). Brasília: IPEA:ABDI. https://www.ipea.gov.br/portal/index.php?option=com_content&view=article&id=26104

Crepón, B., Duguet, E., & Mairesse, J. (1998). Research, innovation and productivity: An econometric analysis at the firm level. *Economics of Innovation and New Technology*, *7*(2), 115–158. http://dx.doi.org/10.1080/10438599800000031

De Negri, F., & Cavalcante, R. (2014). Os dilemas e os desafios da produtividade no brasil. In F. De Negri & R. Cavalcante (Eds.), *Produtividade no Brasil: Desempenho e determinantes* (Vol. 1, pp. 15–52). Brasília: IPEA:ABDI. https://www.ipea.gov.br/portal/index.php?option=com_content&id=23986

Diagne, Y. S. (2013). *Impact of business environment on investiment and output of manufacturing firms in Senegal* [MPRA Paper 57952]. https://mpra.ub.uni-muenchen.de/57952/

Dias, J., & Tebaldi, E. (2012). Institutions, human capital, and growth: The institutional mechanism. *Structural Chance and Economic Dynamics*, *23*(3), 300–312. http://dx.doi.org/10.1016/j.strueco.2012.04.003

Djankov, S., La Porta, R., de Silanes, F. L., & Shleifer, A. (2002). The regulation of entry. *The Quarterly Journal of Economics*, *117*(1), 1–37. http://dx.doi.org/10.1162/003355302753399436

Enders, W. (2010). *Applied econometric time series* (3rd ed.). Wiley.

Ferreira, P. C., & Guillén, O. T. C. (2004). Estrutura competitiva, produtividade industrial e liberalização comercial no Brasil. *Revista Brasileira de Economia*, *58*(4). http://dx.doi.org/10.1590/S0034-71402004000400003

Ferreira, P. C., & Rossi, J. L., Jr. (2003). New evidence from Brazil on trade liberalization and productivity growth. *International Economic Review*, *44*(4), 1383–1405. http://dx.doi.org/10.1111/1468-2354.t01-1-00114

Ferreira, P. C., & Veloso, F. (2013). O desenvolvimento econômico brasileiro no pós-guerra. In F. Veloso, P. C. Ferreira, F. Giambiagi, & S. A. Pessôa (Eds.), *Desenvolvimento econômico: Uma perspectiva brasileira* (pp. 129–165). Rio de Janeiro: Elsevier.

Fontes, A., & Pero, V. (2012). Formalização e ambiente de negócios para micro e pequenas empresas no Rio de Janeiro. In A. C. Pinheiro & F. Velos (Eds.), *Rio de Janeiro: Um estado em transição.* Rio de Janeiro: Editora FGV.

Fraga, G. J. (2016). Foreign direct investment, trade openess and productivity: Evidence from Brazilian industries. *Espacios*, *37*(14). http://es.revistaespacios.com/a16v37n14/16371430.html

Gonçalves, C. E. S. (2008). Produtividade e instituições no Brasil e no mundo: Ensinamentos teóricos e empíricos. In F. Giambiagi & O. Barros (Eds.), *Brasil globalizado: O Brasil em um mundo surpreendente* (pp. 197–225). Rio de Janeiro: Campus.

Griliches, Z. (1979). Issues in assessing the contribution of research and development to productivity growth. *Bell Journal of Economics*, *10*(1), 92–116. http://dx.doi.org/10.2307/3003321

Griliches, Z. (1980). R&D and the productivity slowdown. *The American Economic Review*, *70*(2), 343–348. https://www.jstor.org/stable/1815495

Grossman, G. M., & Helpman, E. (1990). Comparative advantage and long-run growth. *The American Economic Review*, *80*(4), 796–815. https://www.jstor.org/stable/2006708

Hall, R. E., & Jones, C. I. (1999). Why do some countries produce so much more output per worker than others? *The Quarterly Journal of Economics*, *114*(1), 83–116. http://dx.doi.org/10.1162/003355399555954

Hamilton, J. D. (1994). *Time series analysis*. Princeton University Press.

IBGE – Instituto Brasileiro de Geografia e Estatística. (n.d.). *Website.* https://www.ibge.gov.br/

Ipeadata. (n.d.). *Data website.* Retrieved 27 Jan 2017, from http://www.ipeadata.gov.br

Jacinto, P. d. A. (2015). Produtividade nas empresas: Uma análise a partir da escolaridade e da dispersão da produtividade. In F. De Negri & R. Cavalcante (Eds.), *Produtividade no Brasil: Desempenho e determinantes* (Vol. 2, pp. 255–276). Brasília: IPEA:ABDI. https://www.ipea.gov.br/portal/index.php?option=com_content&view=article&id=26104

Kaldor, N. (1978). Causes of the slow rate of economic growth in the United Kingdom. In N. Kaldor (Ed.), *Further essays on economic theory.* Londres: The Anchor Press.

Lavopa, A. (2011, Jan). *The impact of sectoral heterogeneities in economic growth and catching up: empirical evidence for Latin America manufacturing industries* (UNU-MERIT Working Paper No. 075). Maastricht Economic and Social Research Institute on Innovation and Technology. https://cris.maastrichtuniversity.nl/en/publications/the-impact-of-sectoral-heterogeneities-in-economic-growth-and-cat

Magalhães, A. M., Branco, V. C. C., & Cavalcanti, T. V. (2007, Dec). Abertura comercial, crescimento econômico e tamanho dos estados: Evidências para o Brasil. In *35º Encontro Nacional de Economia (ANPEC)*, Recife, PE. http://www.anpec.org.br/encontro2007/artigos/A07A104.pdf

Mation, L. F. (2014). Comparações internacionais de produtividade e impactos do ambiente de negócios. In F. De Negri & R. Cavalcante (Eds.), *Produtividade no Brasil: Desempenho e determinantes* (Vol. 1, pp. 173–200). Brasília: IPEA:ABDI. https://www.ipea.gov.br/portal/index.php?option=com_content&id=23986

Mincer, J. (1958). Investment in human capital and personal income distribution. *Journal of Political Economy*, *66*(4), 281–302. http://dx.doi.org/10.1086/258055

Mincer, J. (1974). *Schooling, experience and earnings*. New York: National Bureau of Economic Research, Columbia University Press. https://www.nber.org/books/minc74-1

Munnel, A. H. (1990). How does public infrastructure affect regional economic performance? *New England Economic Review*, 11–33. https://www.bostonfed.org/-/media/Documents/neer/neer590b.pdf

Mussolini, C. C., & Teles, V. K. (2010). Infraestrutura e produtividade no Brasil. *Revista de Economia Política*, *30*(4), 645–662. http://dx.doi.org/10.1590/S0101-31572010000400006

North, D. C. (1990). *Institutions, institutional change and economic performance*. Cambridge University Press.

North, D. C. (1991). Institutions. *Journal of Economic Perspectives*, *5*(1), 97–112. http://dx.doi.org/10.1257/jep.5.1.97

Pakes, A., & Griliches, Z. (1984). Patents and R&D at the firm level: A first look. In Z. Griliches (Ed.), *R&D, patents, and productivity* (pp. 55–72). Chicago: University of Chicago Press.

PME – IBGE. (n.d.). *Pesquisa mensal de emprego (PME): Microdados de 2004 a 2014.* Retrieved 24 Jan 2017, from https://www.ibge.gov.br/estatisticas/sociais/trabalho/9180-pesquisa-mensal-de-emprego.html?=&t=o-que-e

Romer, P. M. (1990). Endogenous technological change. *Journal of Political Economy*, *98*(5), 71–102. http://dx.doi.org/https://www.jstor.org/stable/2937632

Rossi, J. L. R., Jr, & Ferreira, P. C. (1999). Evolução da produtividade industrial brasileira e abertura comercial. *Pesquisa e Planejamento Econômico*, *29*(1). http://ppe.ipea.gov.br/index.php/ppe/article/view/190

Schettini, D., & Azzoni, C. (2015). Determinantes regionais da produtividade industrial: O papel da infraestrutura. In F. De Negri & R. Cavalcante (Eds.), *Produtividade no Brasil: Desempenho e determinantes* (Vol. 2, pp. 391–414). Brasília: IPEA:ABDI. https://www.ipea.gov.br/portal/index.php?option=com_content&view=article&id=26104

Schultz, T. W. (1961). Investment in human capital. *The American Economic Review*, *51*(1), 1–17. https://www.jstor.org/stable/1818907

Silva, G. G., Jr, da Silveira, J. M., Paranhos, J., Hasenclever, L., & Miranda, R. B. (2015). Produtividade, inovação e poder de mercado na indústria brasileira de transformação. In F. De Negri & R. Cavalcante (Eds.), *Produtividade no Brasil: Desempenho e determinantes* (Vol. 2, pp. 361–390). Brasília: IPEA:ABDI. https://www.ipea.gov.br/portal/index.php?option=com_content&view=article&id=26104

Steingraber, R., & Gonçalves, F. O. (2010). Inovação, instituições e capital social na produtividade total dos fatores da indústria brasileira em 2005. In M. S. Salerno, J. A. D. Negri, L. M. Turchi, & J. M. de Morais (Eds.), *Inovação: Estudos de jovens pesquisadores brasileiros* (Vol. 2, pp. 119–147). São Paulo: Editora Papagaio. https://www.researchgate.net/publication/277703309_Inovacao_estudos_de_jovens_pesquisadores_brasileiros_-_Volume_2

Velloso, R., Matos, C., Mendes, M., & de Freitas, P. S. (2012). *Infraestrutura: Os caminhos para sair do buraco.* Instituto Nacional de Altos Estudos.

World Bank. (n.d.). *Databank: World development indicators.* Retrieved 28 Feb 2017, from http://databank.worldbank.org/data/reports.aspx?source=2&Topic=14

Yano, N. M., & Monteiro, M. M. (2008, Dec). Mudanças institucionais na década de 1990 e seus efeitos sobre a produtividade total dos fatores. In *36º Encontro Nacional de Economia (ANPEC)*, Salvador. http://www.anpec.org.br/encontro2008/artigos/200807211610100-.pdf

r b e
REVISTA BRASILEIRA DE ECONOMIA
DOI 10.5935/0034-7140.20200012
ISSN 1806-9134 (online)
FGV
FUNDAÇÃO GETULIO VARGAS

Uma Nota Sobre o Prêmio Salarial em Empresas Exportadoras Brasileiras

Wallace Patrick Santos de Farias Souza[*]
Flávio Augusto Ziegelmann[†]
Erik Alencar de Figueiredo[‡]

Sumário

1. Introdução 221
2. Dados e Estatísticas Descritivas ...223
3. Procedimentos Metodológicos 227
4. Resultados 228
5. Considerações Finais 231

Palavras-chave
Status de exportação, salários

JEL Codes
C21, C23, J31

Resumo • Abstract

This note investigates the relationship between the export status of companies and the workers salary, testing whether the export leads to a wage employees of foreign companies or whether exporting companies were already paying a higher salary before starting to export. To achieve that, we consider an identified panel data employer-employee from Brazil for the years 2003 to 2013. The results confirm the existence of a self-selection mechanism, where companies pay higher salaries because they are more productive and, consequently, become able to enter the export market.
exportador.

1. Introdução

É um fato estilizado que as empresas que atuam como exportadoras no mercado internacional pagam, em média, salários mais altos que as atuantes apenas no mercado doméstico. Tal argumento tem sido confirmado por vários estudos com dados de empregadores-empregados ao encontrarem uma relação positiva entre as atividades de exportação e nível de salários, mesmo após controlar por características observadas e não observadas dos trabalhadores e das empresas (Munch & Skaksen, 2006; Schank, Schanabel, & Wagner, 2007; Alcalá & Hernández, 2007). Essa lógica da literatura internacional também é válida o Brasil, principalmente após o processo de abertura comercial da década de 1990 (Krishna, Poole, & Senses, 2012). Contudo, o que explica essa diferença salarial? Respostas satisfatórias necessitam do estabelecimento de uma relação causal, se possível determinando o sentido dessa causalidade. Tomando a

[*]Universidade Federal da Paraíba, Programa de Pós Graduação em Economia. Jardim Cidade Universitária, João Pessoa, PB, CEP 58059-356, Brasil. 0000-0002-0598-936X

[†]Universidade Federal do Rio Grande do Sul, Programa de Pós Graduação em Economia. Av. João Pessoa, 52, Centro, Porto Alegre, RS, CEP 90040-001, Brasil. 0000-0001-8899-350X

[‡]Universidade Federal da Paraíba, Programa de Pós Graduação em Economia. Jardim Cidade Universitaria, João Pessoa, PB, CEP 58059-356, Brasil. 0000-0002-3479-3665

wpsfarias@gmail.com flavioz@ufrgs.br eafigueiredo@gmail.com

This is an open-access article distributed under the terms of the Creative Commons Attribution License.

Recebido em 19 de julho de 2018
Aceitação final em 04 de setembro de 2019

investigação desenvolvida por Schank, Schnabel, e Wagner (2010), é preciso verificar se a exportação eleva o prêmio salarial dos empregados ou se as empresas exportadoras já pagam um salário maior antes mesmo de começar a exportar.

Dito isso, o objetivo desta nota é investigar se as firmas brasileiras que atuam no mercado internacional pagam salários maiores em relação as que atendem somente o mercado interno, bem como verificar se esse diferencial de salário já acontecia antes ou apenas quando a firma se torna exportadora. Em outras palavras, será testada qual das hipóteses é válida: 1) a primeira de que a exportação torna as empresas mais produtivas e conduz a maiores salários; ou 2) a segunda de que o salário reflete a autosseleção das empresas mais produtivas com salários mais altos nos mercados exportadores.[1]

Se a hipótese 1 for corroborada, indica que o conhecimento é adquirido após a entrada no comércio internacional a partir de *spillovers* dos compradores assim como por meio da concorrência, que faz com que a empresa seja mais eficiente e, consequentemente, mais produtiva. Dessa forma, a empresa aumenta sua produtividade e paga salários maiores (*ex-post*) pelo que é chamado de aprendizagem por exportação. Por outro lado, a segunda hipótese significa que as empresas exportadoras já são mais produtivas que as não exportadoras e observam-se as empresas mais produtivas (*ex-ante*) se tornando exportadoras. Portanto, se os salários forem mais elevados em empresas mais produtivas,[2] é esperado que essas empresas já pagassem salários maiores antes de começarem a exportar. Há razões muito fortes da relação entre produtividade e exportações destacando evidências em favor da hipótese de autosseleção *ex-ante*, onde empresas mais produtivas são as que começam a exportar. No entanto, é preciso analisar mais detalhadamente a relação entre exportação e salários, sobretudo no contexto de recente abertura comercial brasileira que impacta diretamente na organização do mercado de trabalho.

Para atingir o objetivo proposto, será usado um painel de dados empregador-empregado do Brasil para os anos de 2003 a 2013, fornecidos pela Relação Anual de Informações Sociais (RAIS) no qual contém informações sobre trabalhadores individualmente identificáveis em todos os seus empregadores, em termos de idade, gênero, educação, ocupação, tempo na empresa entre outras características. Além dos dados do trabalhador, são também utilizados variáveis a nível da firma tais como o setor de atividade, se atua no setor privado, número de ocupações diferentes dentro da firma, além de informações sobre variável de interesse, qual seja, o status de exportação da firma[3] oriundas da Secretaria de Comércio Exterior (Secex).

Os resultados mostram que o diferencial de salário já existe antes das empresas começarem a exportar, corroborando com a hipótese de autosseleção no mercado exportador, sendo que as firmas mais produtivas já pagavam salários maiores. As conclusões se mantém quando controladas por características dos trabalhadores e das empresas. Os achados corroboram com a literatura empírica (Melitz, 2003 e

[1] Greenaway e Kneller (2007) argumentam que apenas as empresas mais produtivas de uma indústria poderiam suportar os custos adicionais de entrar em mercados estrangeiros.

[2] Salários mais altos causam maior produtividade. Para mais detalhes ver os modelos de salário eficiência baseados em Shapiro e Stiglitz (1984).

[3] Na seção de dados será explicada como se deu a construção das variáveis, visto que é de interesse ter conhecimento sobre a atuação ou não da firma no mercado exportador bem como o período que a mesma começou a atuar.

Sampson, 2016), que têm apontado já existir um diferencial em termos de salários e/ou produtividade nos anos anteriores ao início da exportação, o que indica a autosseleção para exportar das empresas mais produtivas que pagam salários mais altos.

A seção seguinte apresenta a base de dados e algumas estatísticas descritivas, ao passo que na seção 3 é descrita a estratégia empírica adotada. Os resultados encontrados são apresentados na seção 4 e, por fim, são feitas as considerações finais na seção 5.

2. Dados e Estatísticas Descritivas

Para a análise dessa nota, foram utilizados dados da Relação Anual de Informações Sociais (RAIS) divulgada pelo Ministério do Trabalho e Emprego (MTE), tendo como fonte direta as próprias empresas registradas formalmente que são obrigadas por lei a comunicar anualmente informações sobre cada trabalhador contratado. A base de dados utilizada foi do tipo empregador-empregado em um painel para os anos de 2003 a 2013, que permite acompanhar os trabalhadores e as empresas ao longo dos anos, possibilitando identificar os movimentos entre eles.

Com relação aos trabalhadores há informações sobre raça, sexo, grau de instrução, idade, nacionalidade, salário anual e ocupação baseada na Classificação Brasileira de Ocupações de 2002 (CBO 2002). Quanto às empresas, há informações sobre o identificador do estabelecimento, sobre o seu porte, classificação de atividade, natureza jurídica e quantidade de trabalhadores. Além disso, foram utilizados dados da Secretaria de Comércio Exterior (Secex) sobre o status de exportação das firmas, sendo uma *dummy* que assume valor 1 se a firma for exportadora de qualquer produto para qualquer destino e zero caso contrário.

Em 2003, a amostra conta com 120.901 observações sobre trabalhadores num total de 4.085 firmas enquanto que em 2013, último ano da amostra, corresponde a 98.363 observações para 2.835 empresas. Cabe destacar que para 2013, tem-se que 110 empresas atuavam no mercado exportador.

Para testar as hipóteses sobre a relação entre atividades de exportação e salários mais elevados é preciso comparar, ao longo do tempo, as empresas que começaram a exportar com as que continuam a produzir apenas para o mercado interno. Detalhadamente, dado a possibilidade da firma já pagar maiores salários antes de entrar no mercado internacional, inicia-se a amostra em um momento onde nenhuma firma é exportadora[4] para com o passar do tempo um grupo de firmas se tornarem exportadoras enquanto as demais continuarem a ser não exportadoras. Dessa forma, o painel foi subdividido em períodos de seis anos com janela móvel, onde a variável indicadora de exportação corresponde a uma *dummy* que assume valor 1 se a firma não era exportadora nos três primeiros anos ($t = 1, 2, 3$) mas começou a exportar no quarto ano ($t = 4$), continuando nos outros dois ($t = 5{,}6$). Por outro lado, a variável assume valor zero para as firmas que não exportam em nenhum dos anos do período.

Para o período analisado, os dados para firmas que iniciaram a exportação e firmas não exportadoras foram agrupados em seis *coortes* de seis anos (2003–2008, 2004–2009, 2005–2010, 2006–2011, 2007–2012, 2008–2013), com salários deflacionados a preços

[4]Foi excluída qualquer firma exportadora nesse primeiro momento, pois sendo o primeiro ano da amostra não se sabe quando esta começou a exportar

de 2003 como base. A base final utilizada para as estimações conta com 3.963.095 observações para todo o período, composta por trabalhadores com vínculo ativo e que permaneceram empregados durante esse período. Ainda foram considerados os indivíduos com idade entre 18 a 65 anos em 2003, com carga horária de trabalho de 40 ou mais horas por semana.

A Tabela 1 apresenta as estatísticas descritivas das características dos empregados para os dois grupos de firmas (exportadoras e não exportadoras), apresentado por cada um dos anos da *coorte*. Dessa forma, a primeira coluna ($t = 1$) indica a média do primeiro ano de cada *coorte*, enquanto, pelo mesmo raciocínio, a sexta coluna ($t = 6$) indica a média do último ano de cada *coorte*. É observada uma elevação do salario médio, da idade e da proporção de empregados que possuem nível de escolaridade superior ao longo dos anos de cada *coorte*, tanto para as firmas exportadoras como para as não exportadoras. Por outro lado, a proporção de homens, trabalhadores de cor branca e estrangeiros se mantem praticamente estável para os dois tipos de firmas ao longo das *coortes*, sendo a proporção de estrangeiros muito pequena na amostra.

Quando se compara os empregados das firmas exportadoras com as não exportadoras diretamente em cada coluna, percebe-se um diferencial de salário em favor dos trabalhadores do setor de exportação, chegando a quase R$ 1.000,00 para a média do último ano de cada *coorte* (coluna 6). As firmas exportadoras ainda possuem uma maior proporção de trabalhadores brancos, do sexo masculino, estrangeiros e com nível superior quando comparada as não exportadoras, ao passo que têm um menor percentual de trabalhadores com nível de escolaridade fundamental. Em suma, há, em média, um maior percentual de trabalhadores homens, brancos e com nível educacional elevado nas empresas exportadoras quando comparado com as firmas não exportadoras para um mesmo período, recebendo um maior salário para cada ano da *coorte* analisado.

Por sua vez, a Tabela 2 apresenta as estatísticas descritivas para algumas características agregadas para as empresas onde os trabalhadores estão inseridos, também separadas entre exportadoras e não exportadoras e agrupadas pela média de cada ano correspondente a sua *coorte*. Tal como antes, a primeira coluna corresponde, portanto, a média do primeiro ano de cada *coorte*, e assim sucessivamente.

Analisando a evolução ao longo dos anos das *coortes*, é possível ver uma elevação no número médio de empregados por empresa no setor exportador, um aumento das que exercem atividade na indústria, bem como um leve aumento no número de empresas que atuam no setor privado, chegando a 91% do total nos últimos anos de cada *coorte*. Já para as empresas não exportadoras, há uma redução do número médio de empregados por empresa, das atuantes no setor privado e das micro e pequenas empresas ao longo do tempo. Por nível de atividade, há certa estabilidade nos demais setores para os dois tipos, seguindo praticamente o mesmo ao longo dos anos. Por fim, houve uma redução na média de funcionários que ocupam altos cargos[5] para ambos os tipos, os chamados trabalhadores de colarinho branco (*White Collar*).

Comparando diretamente os dois tipos de firmas, é notada uma concentração de firmas exportadoras nos setores da indústria e serviços, chegando a representar 44% e 35% do total, respectivamente, das firmas no último ano das *coortes*. Para as firmas

[5]Membros superiores do poder público, dirigentes, gerentes, etc.

Tabela 1. Estatísticas Descritivas – Características dos Empregados por coorte.

	Coorte					
Empregados	$t = 1$	$t = 2$	$t = 3$	$t = 4$	$t = 5$	$t = 6$
			Exportadoras			
Salário médio	1.812,28	2.058,66	2.224,93	2.378,43	2.529,83	2.670,46
	(1.995,4)	(2.146)	(2.303,7)	(2.418,3)	(2.584,8)	(2.725,8)
Idade	35,09	36,39	37,55	38,25	39,24	40,25
	(8,35)	(8,29)	(8,29)	(8,22)	(8,2)	(8,19)
Sexo	0,8	0,79	0,79	0,78	0,78	0,79
	(0,39)	(0,4)	(0,4)	(0,41)	(0,4)	(0,4)
Estrangeiro	0,001	0,001	0,001	0,001	0,001	0,001
	(0,04)	(0,04)	(0,03)	(0,03)	(0,03)	(0,03)
Branco	0,54	0,55	0,58	0,61	0,61	0,61
	(0,49)	(0,49)	(0,49)	(0,48)	(0,48)	(0,48)
Fundamental I	0,09	0,08	0,07	0,06	0,06	0,06
	(0,28)	(0,27)	(0,26)	(0,25)	(0,24)	(0,24)
Fundamental II	0,18	0,16	0,17	0,16	0,16	0,16
	(0,38)	(0,37)	(0,37)	(0,37)	(0,36)	(0,37)
Médio	0,46	0,44	0,43	0,43	0,43	0,42
	(0,49)	(0,49)	(0,49)	(0,49)	(0,49)	(0,49)
Superior	0,24	0,28	0,29	0,32	0,33	0,33
	(0,42)	(0,45)	(0,45)	(0,46)	(0,47)	(0,47)
			Não Exportadoras			
Salário médio	1.213,23	1.303,9	1.389,78	1.471,15	1.566,77	1.677,32
	(1.572,5)	(1.694,5)	(1.820)	(1.927,1)	(2.029)	(2.139,2)
Idade	36,57	37,62	38,62	39,58	40,53	41,49
	(8,58)	(8,56)	(8,52)	(8,52)	(8,48)	(8,44)
Sexo	0,7	0,7	0,7	0,7	0,7	0,71
	(0,45)	(0,45)	(0,45)	(0,45)	(0,45)	(0,45)
Estrangeiro	0,0006	0,0006	0,0006	0,0006	0,0006	0,0006
	(0,02)	(0,02)	(0,02)	(0,02)	(0,02)	(0,02)
Branco	0,48	0,48	0,48	0,47	0,47	0,46
	(0,49)	(0,49)	(0,49)	(0,49)	(0,49)	(0,49)
Fundamental I	0,11	0,1	0,09	0,08	0,07	0,06
	(0,31)	(0,3)	(0,28)	(0,27)	(0,26)	(0,25)
Fundamental II	0,28	0,27	0,27	0,25	0,24	0,23
	(0,45)	(0,44)	(0,44)	(0,43)	(0,43)	(0,42)
Médio	0,41	0,42	0,44	0,45	0,46	0,48
	(0,49)	(0,49)	(0,49)	(0,49)	(0,49)	(0,49)
Superior	0,17	0,18	0,18	0,19	0,2	0,21
	(0,38)	(0,38)	(0,39)	(0,39)	(0,4)	(0,41)

Nota: Desvio Padrão entre parênteses.

Fonte: Elaboração dos autores com base nos dados da RAIS.

Tabela 2

Firma	Coorte $t=1$	$t=2$	$t=3$	$t=4$	$t=5$	$t=6$
			Exportadoras			
Nº de empregados	4.935,89 (7.650,62)	6.321,71 (9.587,06)	7.109,95 (11.000,1)	9.690,42 (14.348,56)	8.832,54 (13.512,7)	8.227,25 (11.719,17)
Setor privado	0,87 (0,32)	0,89 (0,31)	0,91 (0,28)	0,91 (0,27)	0,91 (0,28)	0,91 (0,28)
Micro/pequena empresa	0,19 (0,39)	0,23 (0,42)	0,24 (0,42)	0,24 (0,43)	0,22 (0,41)	0,20 (0,40)
Agro e Pesca	0,04 (0,19)	0,03 (0,18)	0,03 (0,17)	0,01 (0,10)	0,008 (0,09)	0,009 (0,09)
Indústria	0,34 (0,47)	0,35 (0,47)	0,40 (0,49)	0,44 (0,49)	0,44 (0,49)	0,44 (0,49)
Construção civil	0,05 (0,23)	0,05 (0,23)	0,05 (0,21)	0,05 (0,22)	0,05 (0,22)	0,05 (0,22)
Comércio	0,22 (0,42)	0,19 (0,39)	0,15 (0,36)	0,14 (0,34)	0,13 (0,33)	0,12 (0,32)
Serviços	0,32 (0,46)	0,35 (0,47)	0,35 (0,47)	0,35 (0,47)	0,35 (0,47)	0,37 (0,48)
White Collar	0,14 (0,20)	0,17 (0,23)	0,18 (0,24)	0,15 (0,22)	0,10 (0,18)	0,05 (0,12)
			Não Exportadora			
Nº de empregados	6.471,2 (1.8191,66)	6.002,20 (15.769,74)	5.566,45 (12.838,0)	4.848,67 (8.536,08)	5.256,65 (8.908,55)	5.990,83 (9.918,68)
Setor privado	0,80 (0,39)	0,79 (0,40)	0,78 (0,41)	0,77 (0,41)	0,76 (0,42)	0,75 (0,42)
Micro/pequena empresa	0,17 (0,37)	0,16 (0,37)	0,16 (0,36)	0,14 (0,34)	0,12 (0,32)	0,10 (0,30)
Agro e Pesca	0,01 (0,12)	0,01 (0,11)	0,01 (0,11)	0,01 (0,11)	0,01 (0,10)	0,01 (0,10)
Indústria	0,10 (0,30)	0,10 (0,30)	0,10 (0,30)	0,10 (0,30)	0,09 (0,29)	0,09 (0,29)
Construção civil	0,05 (0,22)	0,05 (0,22)	0,05 (0,22)	0,05 (0,22)	0,05 (0,22)	0,05 (0,22)
Comércio	0,12 (0,32)	0,12 (0,32)	0,12 (0,32)	0,11 (0,32)	0,11	0,11
Serviços	0,70 (0,45)	0,70 (0,45)	0,70 (0,45)	0,71 (0,45)	0,71 (0,45)	0,72 (0,44)
White Collar	0,11 (0,18)	0,11 (0,18)	0,11 (0,18)	0,09 (0,16)	0,08 (0,16)	0,06 (0,14)

Nota: Desvio Padrão entre parênteses.

Fonte: Elaboração dos autores com base nos dados da RAIS.

não exportadoras apenas o setor de serviços corresponde a algo em torno de 70%, independente do ano observado. Tem-se ainda que o percentual de firmas do setor privado é maior entre as firmas exportadoras. A partir do segundo ano das *coortes*, o número médio de empregados é maior para as firmas exportadoras, dando indícios que as firmas desse setor são maiores.

3. Procedimentos Metodológicos

O modelo empírico empregado para testar o impacto da firma ser exportadora sobre os salários dos trabalhadores segue uma especificação aproximada à empregada por Schank et al. (2010), com a diferença na introdução dos efeitos fixos para tentar controlar a heterogeneidade não observada do empregado e da empresa:

$$\ln W_{ijt} = \beta_0 + \beta_1 Exportador_{ijt} + \beta_2 X_{i,t} + \alpha_i + \gamma_j + \epsilon_{ijt}\,, \tag{1}$$

onde $\ln W_{ijt}$ é o logaritmo do salário do indivíduo i que trabalha na empresa j no período de tempo t. $Exportador_{ijt}$ é a variável dicotômica de interesse com valor 1 para os indivíduos que trabalham em firmas que se tornaram exportadoras a partir do quarto ano de cada *coorte* da amostra e 0 para os trabalhadores de firmas domésticas, $X_{i,t}$ é um vetor de características pessoais dos indivíduos e das firmas nas quais estes trabalham, α_i e γ_j são os efeitos fixos do indivíduo e da firma, respectivamente, e por fim, ϵ_{ijt} é o termo de erro.

A introdução dos efeitos fixos procura captar a influência de características não observadas dos trabalhadores e das firmas fixas no tempo. Porém, é possível que haja fatores não observáveis variantes influenciando tanto a produtividade dos trabalhadores quanto as próprias firmas, que podem viesar os resultados. No entanto, sendo o foco na relação entre salários e *status* de exportação, a variável de interesse ($Exportador_{ijt}$) tenta captar o que acontecia com as empresas antes mesmo de começaram a exportar. A interação desta com as variáveis de tempo também tenta dar uma maior robustez nos resultados, como será visto na próxima seção.

A estimação será feita através da utilização de dados em painel, que permite a distinção entre o grau de variação no nível salarial para um indivíduo ao longo do tempo e a variação entre diferentes indivíduos, permitindo o controle da heterogeneidade individual. No entanto, a ausência dos controles das características não observadas específicas dos trabalhadores pode conduzir a vieses nas estimativas resultantes.

Nos modelos tradicionais, o efeito individual não observado é retratado através da introdução de um conjunto de variáveis *dummies* para cada indivíduo cujo coeficiente será o próprio efeito fixo que compõe uma parte do resíduo da regressão. Em termos práticos, quando existe apenas um efeito fixo alguns métodos usam a estimação a partir do desvio das médias ou em primeira diferença ao invés da inclusão do conjunto de *dummies* entre as variáveis explicativas.[6] No entanto, o modelo de dados em painel a ser estimado na presente nota possui duas dimensões. Um efeito fixo por indivíduo (trabalhador) e outro para cada empresa (empregador), seja exportadora ou não, o que demanda um método apropriado para lidar com essas dimensões.

[6]Ver Angrist e Pischke (2009) e Wooldridge (2010).

Como destacado por Guimarães e Portugal (2009), não existem soluções simples no caso de modelos com mais de um efeito fixo, pois a introdução de *dummies* seria inviável devido ao elevado número de unidades de interesse em cada fonte de heterogeneidade não observada. Desse modo, os autores propõem um processo interativo mais simples para estimar tanto os coeficientes da regressão quanto os próprios efeitos fixos tendo como base o método apresentado por Carneiro, Guimarães, e Portugal (2012), o qual foi empregado na estimação de um modelo de regressão de um conjunto de dados de 26 milhões de observações, mais de 26 variáveis e dois efeitos fixos, trabalhador e firma.[7]

De forma simples, Guimarães e Portugal (2009) mostram que o estimador OLS, $\beta = (X'X)^{-1}X'Y$, é apenas uma das muitas alternativas de solução para o sistema de coeficientes do modelo de regressão linear múltipla. É possível encontrar β utilizando um algoritmo iterativo particionado, repetidamente até a convergência, conhecido como "zig-zag".[8] A vantagem desse procedimento é que ele não requer o cálculo da inversa da matriz.

4. Resultados

A observação das estatísticas descritivas aponta indícios da existência de um prêmio salarial positivo para as empresas exportadoras. No entanto é preciso observar a diferença de salário após o controle de variáveis dos exportadores que podem afetar os salários, além de determinar se esse diferencial já existia antes mesmo da empresa entrar no mercado exportador. Dessa forma, a Tabela 3 apresenta os resultados das estimações, observando a diferença média de salário entre indicadores de exportação e não exportação ao longo do tempo. A variável dependente é o logaritmo do salário médio recebido pelo trabalhador, enquanto que a variável explicativa de interesse é denominada de *Exportador*, uma *dummy* que assume valor 1 se o indivíduo trabalha numa empresa que começou a exportar a partir do quarto ano da *coorte* (dado que antes não era exportadora) e zero se a empresa produz durante toda a *coorte* apenas para o mercado interno (não exportadora), tal como explicado na seção de dados. Os demais controles referem-se a características dos trabalhadores e das empresas a que estão vinculados.

Na primeira coluna são inseridos controles para características pessoais dos empregados, *dummies* para os estados da federação e os dois efeitos fixos tal como descrito na estratégia de estimação: um por indivíduo (trabalhador) e outro por empresa (firma). O coeficiente da variável Exportador mostra um diferencial de salário positivo e significativo para as firmas exportadoras, indicando que mesmo antes de se tornarem exportadoras tal diferencial já poderia estar ocorrendo, visto que essa variável é formada pelas firmas que só começaram a exportar a partir do quarto ano de cada *coorte*. Em outras palavras, há indícios que o salário dos trabalhadores das firmas já é maior mesmo antes destas se tornarem exportadoras.

[7] O algoritmo de Guimarães e Portugal (2009) visa, portanto facilitar a implementação do método de Carneiro et al. (2012), visto a alto custo computacional.

[8] De acordo com Smyth (1996), esse algoritmo produz iterações nas quais os coeficientes estão correlacionados entre si.

Tabela 3. Nível Salarial e Status de Exportação — Painel com Efeitos Fixos.

	Variável Dependente: Log do salário médio		
Empregados	(1)	(2)	(3)
Exportador	0,0161***	0,0084***	0,0077***
	(0,0009)	(0,0013)	(0,0013)
Tempo de vínculo	−0,0001***	−0,0001***	−0,0001***
	(0,0000)	(0,0000)	(0,0000)
Idade	0,1173***	0,1171***	0,1137***
	(0,0001)	(0,0001)	(0,0001)
Idade^2	−0,0007***	−0,0007***	−0,0007***
	(0,0000)	(0,0000)	(0,0000)
Fundamental I	0,0023	0,0023	0,0048
	(0,0039)	(0,0039)	(0,0038)
Fundamental II	−0,0079	−0,0078	−0,0034
	(0,0039)	(0,0039)	(0,0038)
Médio	−0,0175***	−0,0174***	−0,0116***
	(0,0039)	(0,0039)	(0,0039)
Superior	0,1072***	0,1074***	0,0908***
	(0,004)	(0,004)	(0,004)
Estrangeiro	0,0306***	0,0310***	0,0267***
	(0,0101)	(0,0101)	(0,0101)
Dummy $(t = 1) \times Exportador$		0,0082***	0,0088***
		(0,0016)	(0,0016)
Dummy $(t = 2) \times Exportador$		0,0029***	0,0015***
		(0,0011)	(0,0011)
Dummy $(t = 3) \times Exportador$		0,0098***	0,0110***
		(0,0014)	(0,0014)
Dummy $(t = 4) \times Exportador$		0,0154***	0,0147***
		(0,0014)	(0,0014)
Dummy $(t = 5) \times Exportador$		0,0139***	0,0102***
		(0,0014)	(0,0014)
Dummy $(t = 6) \times Exportador$		0,0144***	0,0069***
		(0,0015)	(0,0015)
Indústria			−0,0347***
			(0,0033)
Construção Civil			−0,0344***
			(0,0035)
Comércio			−0,0530***
			(0,0036)
Serviços			0,0510***
			(0,0033)
Trab_Serviços			−0,0482***
			(0,0006)
Técnicos			0,0071***
			(0,0007)
Profissionais			0,0959***
			(0,0009)
Gerentes			0,1502***
			(0,001)
Micro/Pequena Empresa			−0,0110***
			(0,0005)
UF (*Dummies*)	Sim	Sim	Sim
Firma (FE)	Sim (5.801)	Sim (5.801)	Sim (5.801)
Empregado (FE)	Sim (139.852)	Sim (139.852)	Sim (139.852)
Observações	3.957.534	3.957.534	3.957.534
R^2	0,95	0,959	0,96

Notas: Desvio Padrão entre parênteses.
*** $p - valor < 0{,}01$; ** $p - valor < 0{,}05$; * $p - valor < 0{,}10$.

Fonte: Elaboração dos autores com base nos dados da RAIS.

As variáveis de controle para as características dos trabalhadores têm, em geral, o sinal esperando e são estatisticamente significativas.[9] A idade tem um efeito positivo sobre o salário, fato já consolidado na literatura sobre mercado de trabalho, dado que os indivíduos podem acumular qualificação, experiência e outros atributos que aumentam a produtividade com o passar dos anos. Porém esse efeito tem um limite, captado pelo coeficiente negativo da idade ao quadrado. Ter nível superior e ser estrangeiro também afetam positivamente os salários, este último possivelmente pelo fato de ser um pequeno percentual do total de trabalhadores, indivíduos qualificados que migraram de seus países e que ocupam cargos mais elevados. Os resultados para as características individuais se repetem nas outras duas colunas da tabela.[10]

Os coeficientes de interação entre a variável *dummy* indicadora de exportação e as variáveis dummies para cada um dos anos da *coorte* ($t = 1, \ldots, 6$) são acrescentados na coluna 2 da Tabela 3. Como observado, os coeficientes positivos e significativos corroboram e dão robustez a variável Exportador, evidenciando que o prêmio salarial já ocorre desde o primeiro ano ($dummy\ (t = 1) \times Exportador$), mesmo antes da firma começar a exportar.

Por fim, na coluna 3 são acrescentadas características das empresas onde os trabalhadores estão inseridos. Percebe-se um coeficiente negativo para as pessoas que trabalham na indústria, construção civil e comércio quando comparados aos trabalhadores do setor do agronegócio e pesca (categoria base), ao passo que para o setor de serviços o impacto no salário é positivo. Os resultados podem está refletindo, de certa maneira, a importância do agronegócio para a economia brasileira, sobretudo na pauta de exportações.

Com relação ao tipo de ocupação, é verificado um efeito negativo para os trabalhadores de serviços (Trab_Servicos) e positivo para os técnicos de nível médio (técnicos), profissionais de ciências e artes (profissionais) e membros superiores do poder público, dirigentes e gerentes (gerentes), em relação aos trabalhadores da produção de bens e serviços industriais e em serviços de reparo e manutenção – categoria base. A magnitude do coeficiente para a variável Gerentes mostra que independente do setor que atuem, existe um diferencial de salário considerável em relação as demais ocupações. Trabalhar em uma micro ou pequena empresa também afeta negativamente os salários, se comparado a uma empresa média ou de grande porte.

Para as nossas variáveis de interesse, os coeficientes da coluna 3 apresentam o mesmo comportamento da coluna 2. Em suma, os valores positivos e significativos para a variável binária que identifica as firmas exportadoras[11] bem como para sua interação com cada ano da *coorte*, mostram que o diferencial de salário já existia mesmo antes das firmas começarem a exportar.

Estes resultados estão em linha com a hipótese dois apresentada na motivação, de que os salários mais altos seriam pagos antes mesmo das empresas entrarem no mercado exportador, pois estas seriam mais produtivas. Portanto, o salário mais alto

[9] Os comentários referentes aos controles serão sucintos, dado que o foco é a diferença salarial entre exportadores e não exportadores.

[10] As variáveis sexo, raça e setor privado foram omitidas quando estimou-se o modelo de Guimarães e Portugal com efeitos fixos.

[11] Lembrando que a *dummy* identifica as que se tornaram exportadoras a partir do quarto ano.

reflete a autosseleção das empresas mais produtivas, sendo estas as que conseguem entrar nos mercados exportadores. Não é o fato de entrar no mercado exportador que faz pagar maiores salários, e sim pagar maiores salários por ser mais produtiva, e, por conseguinte, se inserir no mercado externo. Os achados também corroboram com as evidências iniciais apontadas nas estatísticas descritivas, onde o salário das empresas exportadoras se mostrou maior que as não exportadoras para todos os anos das *coortes*. Por outro lado, após o inicio da exportação o impacto continua a ser positivo, o que significa que o premio salarial continua a se elevar. No entanto, isso não se deve exclusivamente a exportação.

É importante ainda destacar que os resultados foram controlados olhando apenas para indivíduos que permaneceram na mesma empresa durante todo o período. Isto porque, a seleção das empresas controla apenas as diferenças entre iniciantes de exportação e não exportadores que são invariantes no tempo. Alterações na força de trabalho, como contratações e demissões podem viesar as estimativas.

Os resultados corroboram com os achados de Schank et al. (2010) para a Alemanha, segundo o qual os salários mais elevados nas empresas exportadoras são devidos a autosseleção de empresas que pagam melhor para mercados de exportação. Porém, a magnitude do efeito é menor para o presente estudo, evidenciando que o prêmio salarial é bem inferior para o caso brasileiro.

Em suma, os resultados encontrados corroboram que as firmas eficientes conseguem pagar maiores salários mesmo antes de entrar no mercado exportador e isso está relacionado com a produtividade dos trabalhadores, fazendo com que as firmas sejam auto selecionadas ao mercado externo. Uma das justificativas é que com a penetração no mercado externo aumentam as possibilidades de ganhos, consumidores, acesso a novas tecnologias e mercados em geral, mas por outro lado existem custos adicionais e barreiras à entrada que, em geral, apenas as firmas mais eficientes e produtivas conseguem suportar.

5. Considerações Finais

A presente nota investigou como o status de exportação das empresas pode afetar o salário recebido pelos seus empregados, ou seja, foi testado se entrar no mercado exportador leva a um prêmio salarial para os empregados das empresas do setor externo ou se as empresas exportadoras já pagam um salário maior antes de começar a exportar. A estratégia empírica seguiu o método de Guimarães e Portugal (2009) para as estimativas na média com a inclusão de efeitos fixos para os empregados e as empresas, com um painel de dados sobre empregador-empregado do Brasil para os anos de 2003 a 2013, fornecidos pela Relação Anual de Informações Sociais (RAIS).

Os resultados indicam que já existe um diferencial de salário para os trabalhadores das empresas exportadoras mesmo antes dessas entrarem no mercado externo, o que está em linha com a segunda hipótese apresentada no artigo, de que seriam as empresas mais produtivas que conseguiriam entrar no mercado exportador e por isso já pagariam (*ex ante*) maiores salários. Os achados corroboram com Schank et al. (2010) para a Alemanha, porém com efeito de magnitude menor para o caso brasileiro.

Portanto, o salário mais alto reflete a autosseleção das empresas mais produtivas, sendo estas as que conseguem entrar nos mercados exportadores. Não é o fato de entrar

no mercado exportador que faz pagar maiores salários, e sim pagar maiores salários por ser mais produtiva, e, por conseguinte, se inserir no mercado externo.

Referências bibliográficas

Alcalá, F., & Hernández, P. J. (2007). *Firm characteristics, labor sorting, and wages* (Paper ID Nº 1226). Munich Personal RePEc Archive. https://mpra.ub.uni-muenchen.de/1226/

Angrist, J. D., & Pischke, J. (2009). *Mostly harmless econometrics: An empiricist's companion*. Princeton: Princeton University Press.

Carneiro, A., Guimarães, P., & Portugal, P. (2012). Real wages and the business cycle: Accounting for worker and firm heterogeneity. *American Economic Journal: Macroeconomics*, *4*(2), 133–152. http://dx.doi.org/10.1257/mac.4.2.133

Greenaway, D., & Kneller, R. R. (2007). Firm heterogeneity, exporting and foreign direct investment. *The Economic Journal*, *117*(517), F134–F161. http://dx.doi.org/10.1111/j.1468-0297.2007.02018.x

Guimarães, P., & Portugal, P. A. (2009, janeiro). *Simple feasible alternative procedure to estimate models with high-dimensional fixed effects* (IZA DP Nº 3935). Bonn, Germany: Forschungsinstitut zur Zukunft der Arbeit (IZA). https://www.iza.org/publications/dp/3935/a-simple-feasible-alternative-procedure-to-estimate-models-with-high-dimensional-fixed-effects

Krishna, P., Poole, J. P., & Senses, M. Z. (2012). Trade, labor market frictions, and residual wage inequality across worker groups. *American Economic Review*, *102*(3), 417–423. http://dx.doi.org/10.1257/aer.102.3.417

Melitz, M. J. (2003). The impact of trade on intra-industry reallocations and aggregate industry productivity. *Econometrica*, *71*(6), 1695–1725. http://dx.doi.org/10.1111/1468-0262.00467

Munch, J. R., & Skaksen, J. R. (2006, outubro). *Human capital and wages in exporting firms* (IZA DP Nº 2409). Bonn, Germany: Forschungsinstitut zur Zukunft der Arbeit (IZA). https://www.iza.org/publications/dp/2409/human-capital-and-wages-in-exporting-firms

Sampson, T. (2016). Dynamic selection: An idea flows theory of entry, trade, and growth. *Quarterly Journal of Economics*, *131*(1), 315–380. http://dx.doi.org/10.1093/qje/qjv032

Schank, T., Schanabel, C., & Wagner, J. (2007). Do exporters really pay higher wages? First evidence from German linked employer-employee data. *Journal of International Economics*, *72*(1), 52–72. http://dx.doi.org/10.1016/j.jinteco.2006.08.004

Schank, T., Schnabel, C., & Wagner, J. (2010). Higher wages in exporting firms: Self selection, export effect, or both? First evidence from linked employer-employee data. *Review of World Economics*, *146*(2), 303–322. http://dx.doi.org/10.1007/s10290-010-0049-7

Shapiro, C., & Stiglitz, J. E. (1984). Equilibrium unemployment as a worker discipline device. *American Economic Review*, *74*(3), 433–444. http://dx.doi.org/https://www.jstor.org/stable/1804018

Smyth, G. (1996). Partitioned algorithms for maximum likelihood and other nonlinear estimation. *Statistics and Computing*, *6*, 201–216. http://dx.doi.org/10.1007/BF00140865

Wooldridge, J. M. (2010). *Econometric analysis of cross section and panel data*. Massachusetts: MIT Press.