

Crescimento econômico regional e complexidade: o papel das microempresas e dos MEI

Alberto Ribeiro Vallim¹  | Leonardo Monasterio² 

¹ Sebrae e IDP - Brasília. E-mail: albertorvallim@gmail.com

² Instituto de Pesquisa Econômica Aplicada - Rio de Janeiro, IDP - Brasília e CNPq. E-mail: leonardo.monasterio@gmail.com

RESUMO

Este estudo estima a relação entre a complexidade e o crescimento econômico regional do Brasil entre 2008 e 2019. A principal contribuição deste trabalho está na inclusão de pequenas empresas sem empregados e microempreendedores individuais na construção dos indicadores de complexidade. Para isso, foram utilizados, além dos dados da RAIS, aqueles de CNPJ fornecidos pela Receita Federal. Foram calculados três índices de complexidade com bases de dados distintas: ICE^A (empresas, incluindo MEI), ICE^B (empresas, exceto MEI) e ICE^V (apenas vínculos empregatícios). Regressões de crescimento, com os devidos controles, mostraram que esses novos indicadores de complexidade estiveram associados ao crescimento econômico das microrregiões no período. Os resultados reforçam a importância de atenção à metodologia de cálculo das medidas de complexidade. Apesar das limitações do estudo e das características do período, a hipótese de que a complexidade local influencia o crescimento econômico não foi refutada.

PALAVRAS-CHAVE

Complexidade econômica, Pequenas empresas, Desenvolvimento regional

Economic Regional Growth and Complexity: The Role of Microenterprises and MEI

ABSTRACT

This study estimates the relationship between complexity and regional economic growth in Brazil from 2008 to 2019. The main contribution of this study lies in the inclusion of small businesses without employees and individual micro-entrepreneurs in the construction of complexity indicators. For this purpose, in addition to RAIS data, CNPJ data provided by the Brazilian Federal Revenue Service were used. Three complexity indexes were calculated using different databases: ICE^A (companies, including MEI), ICE^B (companies, excluding MEI), and ICE^V (only employment relationships). Growth regressions, with appropriate controls, showed that these new complexity indicators were associated with the economic growth of micro-regions in the period. The results reinforce the importance of careful attention to the methodology of calculating complexity measures. Despite the limitations of the study and the characteristics of the period, the hypothesis that local complexity influences economic growth was not falsified.

KEYWORDS

Economic complexity, Small businesses, Regional development

CLASSIFICAÇÃO JEL

L16, O47

1. Introdução

A abordagem da *Complexidade Econômica* de Hidalgo et al. (2007); Hidalgo e Hausmann (2009); Hausmann et al. (2013) foi fundamental para uma melhor compreensão das relações entre a estrutura produtiva das regiões e o crescimento econômico. Contudo, pouca atenção tem sido dada nesta literatura ao tema das pequenas empresas, que compõem a maioria das firmas brasileiras. Este trabalho busca, assim, avaliar o quanto a inclusão do universo de pequenas empresas no cálculo da complexidade econômica afeta as estimativas do seu impacto sobre o PIB *per capita* das microrregiões.

Os estudos de Hidalgo et al. (2007); Hidalgo e Hausmann (2009); Hausmann et al. (2013) propuseram uma forma de medir a complexidade da estrutura produtiva dos países, denominada *Índice de Complexidade Econômica*, baseada na diversidade de exportações dos países e na ubiquidade dos produtos exportados por cada um deles. Aliando diversidade e ubiquidade, o índice representa o volume de conhecimentos acumulados e combinados na rede de interações de uma economia. Os referidos autores mostraram que tal índice tem relação com os níveis de renda *per capita* e, mais do que isso, que um aumento na complexidade econômica está relacionado com maiores taxas de crescimento da renda *per capita* nos anos seguintes (Hausmann et al., 2013).

Um importante desdobramento foi a aplicação da metodologia em níveis subnacionais. Utilizando também dados de exportações, houve aplicações para o nível das unidades federativas brasileiras (Romero e Gramkow, 2021) e diversos outros trabalhos que utilizaram o cálculo do *Índice de Complexidade Econômica* para unidades federativas e municípios (DataViva, 2017; Cimini et al., 2018; Garcez et al., 2019; Medeiros et al., 2020).

Porém, para níveis subnacionais mais desagregados, como microrregiões ou municípios, estudos com dados de exportações possuem as seguintes limitações: (i) ausência de dados; (ii) muitos locais com poucos ou nenhum tipo de produto exportado; (iii) ênfase nos setores industrial e agropecuário, em detrimento de comércio e serviços; e (iv) dados não contemplam o mercado interno, ou seja, o comércio entre os entes subnacionais, geralmente mais intenso que o internacional. Desta maneira, o foco apenas nas exportações distorce a medida da complexidade produtiva local.

Além de dados de exportação, outras variáveis foram utilizadas para aplicar a metodologia do índice, como dados de patentes (Balland et al., 2018) e de empregos (Gao et al., 2021; Freitas, 2019; Fagundes et al., 2019). As aplicações com dados de empregos ampliam o alcance territorial, pois permitem análises de todos os perfis de municípios. Há, porém, outra limitação. Apenas empresas que possuem empregados aparecem na base de dados, o que impede uma visão da realidade que contemple pequenas empresas sem funcionários e microempreendedores individuais (MEI), categorias bastante numerosas no universo de empresas do Brasil.

Desde o início da vigência do MEI, entre 2009 e 2010, a quantidade de empreendedores que utilizam essa figura jurídica cresceu rapidamente, tornando-a a maior categoria entre os portes empresariais¹ (ver Figura 1 na seção 3.4). Surpreendentemente, contudo, não há na literatura nacional aplicações da metodologia do *Índice de Complexidade Econômica* que incluam o MEI e as pequenas empresas sem empregados. Assim, justifica-se a relevância dessa nova aplicação pelos seguintes motivos: (i) ampliação da abrangência do *Índice de Complexidade Econômica* para grupos empresariais muito numerosos, mas até então ignorados; (ii) ampliação da granularidade territorial do índice, já que a base do CNPJ cobre todos os municípios brasileiros e há empresas em todos os municípios; (iii) ampliação do conhecimento sobre o microempreendedor individual (MEI) e suas relações com crescimento econômico dos territórios.

A seção seguinte deste trabalho faz uma revisão da literatura internacional e nacional acerca da complexidade econômica e de suas aplicações. Na terceira seção, são abordados a metodologia de cálculo do *Índice de Complexidade Econômica*, os modelos utilizados neste trabalho e detalhamentos importantes para a compreensão dos dados utilizados. A quarta seção apresenta os resultados dos índices calculados para as microrregiões brasileiras. A quinta seção traz os resultados das regressões propostas, que continuam sendo explorados nos testes de robustez da sexta seção. Por fim, a sétima seção mostra as conclusões do estudo.

2. Revisão de Literatura

A metodologia do Índice de Complexidade Econômica foi construída por Hidalgo et al. (2007); Hidalgo e Hausmann (2009); Hausmann et al. (2013) e parte dos cálculos de diversificação dos países, ubiquidade dos produtos e das “Vantagens Comparativas Reveladas – VCR” (Balassa, 1965) para cada país e produto (no caso deste estudo, serão microrregiões e atividades econômicas). A VCR é uma medida obtida pela proporção que um país exporta de certo produto em relação ao total de suas exportações dividida pela proporção daquele produto no mercado mundial de exportações de todos os produtos. Sendo a $VCR \geq 1$ (conforme escolha feita por Hausmann e Hidalgo), o país possui vantagem naquele produto.

Hidalgo et al. (2007) propuseram a utilização da VCR para criar a rede *Product Space*, que permitiu analisar o custo e a velocidade com que um país poderia se movimentar nessa rede e buscar VCR em produtos nos quais ainda não tinha. A ideia foi aprimorada em Hidalgo e Hausmann (2009) pela introdução do conceito de ubiquidade dos produtos e do Método de Reflexões, que é usado iterativamente para combinar as variáveis de diversificação e ubiquidade para chegar à complexidade econômica. Os autores ainda aprimoraram o trabalho com a publicação *The Atlas of Economic Com-*

¹Os portes empresariais aqui utilizados são as faixas de faturamento anual definidas pelas leis 123/2006, 128/2008 e atualizações até 2019: MEI (Microempreendedor Individual) até R\$ 81 mil, com requisitos adicionais; ME (Microempresa) até R\$ 360 mil; EPP (Empresa de Pequeno Porte) acima de R\$ 360 mil e até R\$ 4,8 milhões; demais portes acima de R\$ 4,8 milhões e outras situações específicas.

plexity (Hausmann et al., 2013), na qual exploraram com mais detalhes as comparações da variável de complexidade com outras formas de medir o desenvolvimento e publicaram os resultados para todos os países com dados disponíveis.

A abordagem da complexidade tem sido aplicada para analisar a complexidade econômica de diferentes países e identificar a relação entre a diversificação da produção e o desenvolvimento econômico. Em estudos de países específicos, como Ruanda Hausmann e Chauvin (2015) e Panamá Hartmann et al. (2017), a análise da rede *Product Space* permitiu identificar produtos que estavam dentro das capacidades produtivas e fatores de produção locais, propiciando a criação de estratégias de desenvolvimento econômico com base em áreas de especialização. Outros estudos mostraram que a concentração de atividades econômicas complexas em grandes cidades pode estar relacionada à difusão de capacidades econômicas entre diferentes setores (Balland et al., 2018).

Além disso, a análise da complexidade econômica pode estar relacionada a questões como a desigualdade de renda e as emissões de gases do efeito estufa. Países que exportam produtos complexos tendem a ter níveis mais baixos de desigualdade de renda e menor emissão de gases do efeito estufa, principalmente devido à natureza desses produtos, que possuem maior nível tecnológico e maior agregação de valor (Hartmann et al., 2017; Romero e Gramkow, 2021). Esses estudos destacam a importância da diversificação da produção e do desenvolvimento de setores mais complexos para o desenvolvimento econômico sustentável.

Já no caso brasileiro, Romero e Silveira (2019) reproduziram o cálculo da complexidade econômica para as unidades federativas brasileiras para identificar setores promissores para o desenvolvimento de cada uma, além de estimarem também prováveis impactos sobre o produto local.

O cálculo do índice de complexidade com base nas exportações foi disponibilizado no nível de estados e municípios brasileiros na plataforma DataViva, em 2017, ensejando a produção de uma série de estudos. Houve aplicações, por exemplo, para a análise da estrutura produtiva de Santa Catarina (Garcez et al., 2019); para análise da estrutura atual e identificação de oportunidades para sofisticação econômica para Minas Gerais (DataViva, 2017; Cimini et al., 2018); e para análise e proposições para o Espírito Santo (Medeiros et al., 2020).

Adaptando a metodologia para usar dados de quantidade de empregos, em vez de volume de exportações, Fagundes et al. (2019) estudaram a estrutura econômica de Mato Grosso. Essa alteração permitiu enxergar melhor nos resultados os municípios pequenos e médios, sem pauta exportadora relevante. O estudo conseguiu identificar uma razoável expansão da diversificação produtiva, mas com pequena evolução nos níveis de complexidade no período analisado (2006 a 2016). Um dos motivos encontrados para isso foi que a diversificação ocorreu em atividades com valores altos de ubiquidade, o que é algo esperado para municípios com pouca complexidade econô-

mica e parecidos entre si.

O trabalho mais próximo do presente estudo é o de Freitas (2019). Trata-se de uma aplicação da abordagem da complexidade a partir de dados de emprego, no nível territorial das microrregiões brasileiras. A pesquisa identificou que a especialização produtiva das regiões é condicionada pela estrutura já existente, no que é comumente chamado de processo dependente de trajetória. A diversificação, em geral, ocorre em setores relacionados às especializações já instaladas e novas indústrias dificilmente são atraídas quando a distância tecnológica para a estrutura existente for grande. Ainda mais recentemente, dois trabalhos contribuíram para análises subnacionais da complexidade produtiva no Brasil. Carvalho et al. (2022) utilizaram as técnicas de *Propensity Score Matching* (PSM) e Diferenças-em-Diferenças (DID) - para tentar estabelecer uma relação causal entre complexidade e PIB *per capita* no nível municipal. Os resultados sugerem que os municípios que aumentaram a complexidade tiveram taxas de crescimento substantivamente mais altas no período 2009-2019. Já Queiroz et al. (2023) recorreram ao instrumental da complexidade para identificar os setores promissores em cada estado brasileiro. Suas simulações indicam um impacto relativamente modesto: caso os estados se tornassem competitivos nas atividades promissoras apontadas pelo estudo, um total de 81 mil empregos seriam criados no Brasil.

3. Metodologia

3.1 Metodologia de cálculo do Índice de Complexidade Econômica

O primeiro passo para o cálculo do índice é montar a matriz das VCR. Para um país c e um produto p , o cálculo da VCR pode ser definido pela equação:

$$VCR_{cp} = \frac{E_{cp}/\sum_p E_{cp}}{\sum_c E_{cp}/\sum_c \sum_p E_{cp}} \quad (1)$$

Na qual E são as exportações.

Quando a $VCR \geq 1$, o país possui vantagem naquele produto. A partir disso, a diversificação de um país c é dada pelo número de produtos que ele exporta com $VCR \geq 1$, e a ubiquidade de um produto p é dada pelo número de países que o exportam com $VCR \geq 1$ (Hausmann et al., 2013).

A partir de uma matriz com as VCR de todos os países e produtos, calculam-se a diversificação e a ubiquidade:

$$\text{Diversificação de um país} = k_{c,0} = \sum_p M_{cp} \quad (2)$$

$$\text{Ubiquidade de um produto} = k_{p,0} = \sum_c M_{cp} \quad (3)$$

Em que M é uma matriz de adjacências indicando o valor 1 nos cruzamentos em que o país c tiver VCR para o produto p , e o valor 0 se não tiver. O zero subscrito em

$k_{c,0}$ e $k_{p,0}$ indica que esses valores são o ponto de origem para uma série de iterações alternadas entre os índices.

A diversificação $k_{c,0}$ é usada para calcular a diversificação média dos países que exportam determinado produto ($k_{p,1}$); a ubiquidade $k_{p,0}$ é usada para calcular a ubiquidade média dos produtos exportados por cada país ($k_{c,1}$). As iterações subsequentes podem ser representadas pelas equações:

$$k_{c,N} = \sum_p M_{cp} k_{p,N-1} \left(\frac{1}{k_{c,0}} \right) \quad (4)$$

$$k_{p,N} = \sum_c M_{cp} k_{c,N-1} \left(\frac{1}{k_{p,0}} \right) \quad (5)$$

Como é um processo iterativo, o Índice de Complexidade Econômica de um país (ICE_c) e o Índice de Complexidade de um Produto (ICP_p) dependem um do outro. Empiricamente, os autores verificaram que as posições dos países no *ranking* dos índices calculados tendiam a se estabilizar à medida que o número de iterações crescia. E, por meio de testes de regressão, identificaram que um N igual a 18 era suficiente para que os índices tivessem correlação positiva com o log do PIB *per capita*.

Dessa forma, para calcular os índices considerando todas essas iterações, eles montam as equações no formato (Hidalgo, 2021):

$$ICE_c = \left(\frac{1}{M_c} \right) \sum_p M_{cp} ICP_p \quad (6)$$

$$ICP_p = \left(\frac{1}{M_p} \right) \sum_c M_{cp} ICE_c \quad (7)$$

Sendo equações lineares, podem ser reescritas como:

$$ICE_c = \tilde{M}_{cc'} ICE_{c'} \quad (8)$$

$$ICP_p = \tilde{M}_{pp'} ICP_{p'} \quad (9)$$

Nas quais:

$$\tilde{M}_{cc'} = \sum_p \frac{M_{cp} M_{c'p}}{M_c M_p} \quad (10)$$

$$\tilde{M}_{pp'} = \sum_c \frac{M_{cp} M_{cp'}}{M_c M_p} \quad (11)$$

O subscrito c' indica todos os países exceto o país c . Da mesma forma, o subscrito p' indica todos os produtos exceto p .

Os autores demonstram que a solução para o sistema formado pelas Equações 6 e 7 são os autovetores das matrizes $\tilde{M}_{cc'}$ e $\tilde{M}_{pp'}$. Como são matrizes de transição estocástica, o autovetor associado ao maior autovalor é formado apenas por valores 1 e, por isso, sem informação. Assim, o autovetor \vec{K} associado ao segundo maior autovalor das matrizes é definido como a solução para o sistema e indica os índices (Hidalgo, 2021, p.99). Por fim, para chegar ao *ICE* e *ICP* finais, os autores propõem a padronização da transformação:

$$ICE = \frac{\vec{K}_c - \text{média}(\vec{K}_c)}{\text{desv.pad.}(\vec{K}_c)} \quad (12)$$

$$ICP = \frac{\vec{K}_p - \text{média}(\vec{K}_p)}{\text{desv.pad.}(\vec{K}_p)} \quad (13)$$

3.2 Modelos

O objetivo do trabalho é responder: o *Índice de Complexidade Econômica* calculado pela “quantidade de empresas por atividade econômica no território” possui poder explicativo do PIB *per capita*? Ademais, essa relação é tão relevante quanto o índice calculado pela “quantidade de vínculos empregatícios por atividade econômica no território”?

Para tanto, foram calculados três diferentes índices para cada microrregião:

- ICE^A : índice calculado pela quantidade de pessoas jurídicas empresariais por atividade econômica (base de dados do CNPJ/RFB), considerando todos os portes.
- ICE^B : similar ao anterior, porém excluindo o MEI, ou seja, considerando apenas ME, EPP e Demais Portes².
- ICE^V : índice calculado pela quantidade de vínculos empregatícios por atividade econômica (base de dados da RAIS).

Na regressão em que identificam a relação do *ICE* com o PIB *per capita*, Hausmann et al. (2013) incluem a variável “exportações de recursos naturais” como controle. Neste trabalho, há uma situação semelhante: foram utilizados dados apenas das pessoas jurídicas com naturezas jurídicas empresariais, tanto da base do CNPJ quanto da RAIS. Por isso, a agropecuária está sub-representada, já que boa parte da produção desse setor se dá por produtores rurais com outros tipos de registro que não o CNPJ. O mesmo ocorre em relação ao setor público. Sendo assim, foram incluídas

²Mais detalhes sobre os portes empresariais na nota de rodapé 1

nos modelos as variáveis de Valor Adicionado da Agropecuária e da Administração Pública como controle.

Primeiramente, foi realizada uma regressão de mínimos quadrados ordinários para estimar a associação entre os índices de complexidade econômica e a variação do PIB *per capita* das microrregiões brasileiras no período de 2008 e 2019:

$$\Delta Y_i = \beta_0 + \beta_1 Y_{i,0} + \beta_2 \Delta V A_i^{AGRO} + \beta_3 \Delta V A_i^{PUB} + \beta_4 ICE_{i,5y} + \beta_5 \log(POP_{i,0}) + \beta_6 \log(EDU_{i,0}) + \epsilon_i \quad (14)$$

Na qual:

- i é o indicador de cada microrregião;
- ΔY_i é a variação do PIB *per capita* de cada microrregião no período;
- β_0, β_1, \dots : coeficientes da regressão;
- $Y_{i,0}$: PIB *per capita* inicial de cada microrregião (2008);
- $\Delta V A_i^{AGRO}$: variação do Valor Adicionado da Agropecuária no período;
- $\Delta V A_i^{PUB}$: variação do Valor Adicionado da Administração Pública no período;
- $ICE_{i,5y}$: média dos 5 primeiros anos do índice de complexidade econômica;
- $\log(POP_{i,0})$: logaritmo da população inicial (2008);
- $\log(EDU_{i,0})$: logaritmo da Expectativa de Anos de Estudo inicial (esta variável será do ano de 2010, único em que há disponibilidade no nível necessário);
- ϵ_i : ruído aleatório da regressão.

Adicionalmente, foi feita uma estimação de dados em painel com efeitos fixos individuais e temporais. Esse tipo de regressão permitirá controlar os resultados para variáveis não observáveis (de cada microrregião e de cada ano do período estudado) que eventualmente tenham influência na variação do PIB *per capita*. A regressão de efeitos fixos foi montada da seguinte forma:

$$\log(Y_{i,t}) - \log(Y_{i,t-1}) = \alpha_i + \gamma_t + \beta_1 \log(Y_{i,t-1}) + \beta_2 [\log(V A_{i,t}^{AGRO}) - \log(V A_{i,t-1}^{AGRO})] + \beta_3 [\log(V A_{i,t}^{PUB}) - \log(V A_{i,t-1}^{PUB})] + \beta_4 ICE_{i,t-1} + \epsilon_{i,t} \quad (15)$$

Na qual:

- i : indicador de cada microrregião e t indicador de ano;

- $\log(Y_{i,t}) - \log(Y_{i,t-1})$ são as diferenças em logaritmo do PIB *per capita* de cada microrregião, ano a ano;
- α_i : efeitos fixos individuais, ou seja, de cada microrregião;
- γ_t : efeitos fixos de tempo, ou seja, de cada ano;
- $\log(Y_{i,t-1})$: logaritmo do PIB *per capita* de cada microrregião no ano anterior;
- $\left[\log(VA_{i,t}^{AGRO}) - \log(VA_{i,t-1}^{AGRO}) \right]$ são as diferenças em logaritmo do Valor Adicionado da Agropecuária;
- $\left[\log(VA_{i,t}^{PUB}) - \log(VA_{i,t-1}^{PUB}) \right]$ são as diferenças em logaritmo do Valor Adicionado da Administração Pública;
- $ICE_{i,t-1}$: índice de complexidade econômica no ano anterior;
- $\epsilon_{i,t}$: ruído aleatório da regressão.

3.3 Observações sobre os dados utilizados

O recorte temporal utilizado justifica-se por dois motivos: (i) 2008 foi escolhido como início porque antecede a criação do MEI, que entrou em vigência entre 2009 e 2010; (ii) 2019 foi escolhido como ponto final por ser o ano mais recente com dados disponíveis e antes dos choques causados pela pandemia da covid-19.

Em relação ao nível territorial, maior desagregação contribui para que a análise contemple melhor as localidades de menor população e renda. Porém, o nível de município, ainda que ideal na desagregação, traz muitos casos extremos de PIB *per capita* e de quantidade de empresas e empregos em certas atividades econômicas. Assim, foi escolhido o nível de microrregiões, para manter alguma desagregação, mas suavizar os problemas do nível municipal.

A quantidade de empresas por microrregião e por atividade econômica foi obtida por meio da base pública do Cadastro Nacional da Pessoa Jurídica – CNPJ, disponibilizada pela Receita Federal (Brasil, 2019). Esse conjunto de dados contém todos os CNPJs já criados, indicando sua situação de atividade, porte, entre outras variáveis de interesse. É possível estimar a quantidade de CNPJs ativos em anos anteriores, com pequena margem de erro, utilizando variáveis como data de início de atividade e data de atualização da situação cadastral.


A quantidade de empregos por microrregião e por atividade econômica foi obtida por meio das bases públicas da Relação Anual de Informações Socioeconômicas – (RAIS, 2019) (2008 a 2019). O PIB *per capita* das microrregiões veio do PIB municipal e da população estimada para os anos do estudo (IBGE, 2019a,b) (2008 a 2019). Dados da variável “Expectativa de Anos de Estudo” são oriundos do Censo 2010 (PNUD, 2013).

O tratamento e a manipulação das bases foram realizados no *software* R. Este cálculo, por sua vez, foi realizado por meio de pacote específico denominado *economic-complexity*, que conta com funções para cálculo da matriz de VCR, dos índices de complexidade de países e produtos, entre outras métricas (Vargas, 2020).

3.4 Observações sobre o MEI

Conforme exposto, o *Índice de Complexidade Econômica* foi calculado com três diferentes amostras, resultando nos índices ICE^A (empresas, incluindo MEI), ICE^B (empresas, exceto MEI), ICE^V (vínculos empregatícios). A opção pelos índices com e sem o MEI deve-se ao grande crescimento que essa categoria obteve no período em análise (Figura 1).

Figura 1. Evolução da quantidade de CNPJs empresariais no Brasil, por porte (em milhões)




Fonte: Elaboração e estimativas próprias a partir da base do CNPJ/RFB disponibilizada em 28/05/2020.

Três fatores certamente contribuíram para o crescimento desproporcional do MEI frente às demais categorias: (i) formalização: entrada no MEI de empreendedores autônomos anteriormente sem registro; (ii) empreendedorismo: migração para o MEI de trabalhadores assalariados que decidiram ter um negócio próprio (seja por oportunidade ou necessidade); (iii) *pejotização*: migração para o MEI de trabalhadores assalariados que permaneceram prestando serviços para as empresas que os contratavam anteriormente.

A *pejotização* pode representar um problema tanto para os dados do CNPJ quanto para os dados da RAIS, na medida em que artificialmente aumentaria a quantidade de empresas e diminuiria a quantidade de vínculos empregatícios. Há indícios da associação entre o MEI e a *pejotização* (Corseuil et al., 2014), mas os autores reforçam que outros estudos são ainda necessários.

Estudos do Sebrae sobre o Perfil do MEI fortaleceram o peso dos fatores (i) formalização e (ii) empreendedorismo, e minimizaram a força da (iii) *pejotização*. A favor da (i) formalização, estão dados mostrando um aumento do “grau de cobertura” do MEI, um indicador que mede a proporção de MEI em relação ao total de trabalhadores por conta própria (Figura 2) (SEBRAE – Serviço Brasileiro de Apoio às Micro e Pequenas Empresas, 2019, p.23).

Figura 2. Grau de cobertura do MEI em relação ao total de trabalhadores por conta própria



Fonte: Sebrae (2019) a partir de dados da Receita Federal e PNAD Contínua (IBGE).

Já outra pesquisa quantitativa entrevistou 6.456 MEIs em todo o país e mostrou que a *pejotização* ocorreu para um número muito reduzido. Considerando todos os MEIs, apenas 3% se enquadravam nos critérios da *pejotização*: saíram de uma condição de empregados com carteira assinada, seguiam na mesma atividade e na mesma empresa em que eram funcionários (SEBRAE – Serviço Brasileiro de Apoio às Micro e Pequenas Empresas, 2022, p. 46, 50 e 52).

Portanto, pode-se afirmar que o fenômeno da *pejotização* existe, especialmente em atividades econômicas em que o modelo de negócio favorece esse tipo de relação³, mas que talvez não seja significativo a ponto de enviesar de forma grave o cálculo dos índices.

4. Índices de Complexidade Econômica

As bases de dados do CNPJ e da RAIS foram consolidadas para se chegar às quantidades de empresas e de vínculos empregatícios, respectivamente. Assim, usando

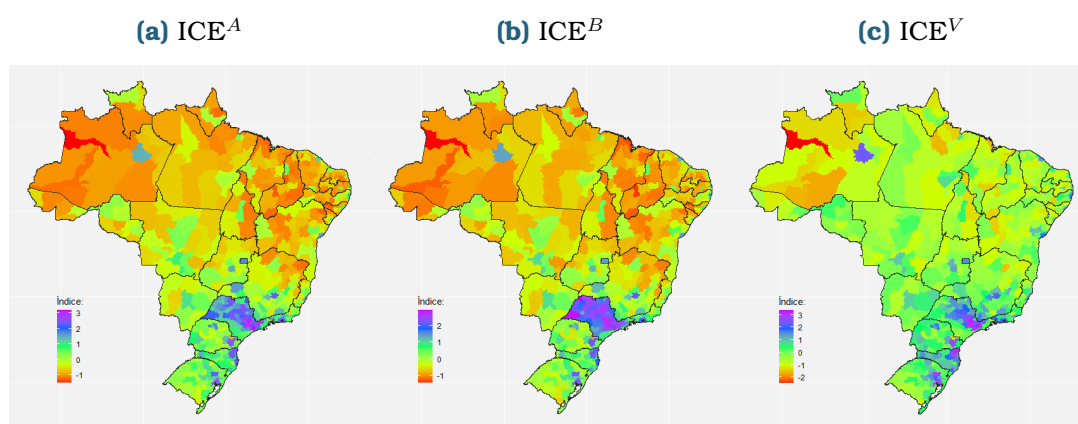
³Por exemplo, o caso dos salões de beleza, atividade que contou com lei específica (Lei nº 13.352/2016, Lei do Salão Parceiro) para regulamentar um regime que muitos entendem como *pejotização*.

as microrregiões como nível espacial de análise e as classes da CNAE como produto, foram calculados os três índices para cada ano do período 2008–2019.

A Tabela 1 mostra as microrregiões com maiores e menores índices no ano de 2019.

Percebe-se na Tabela 1 que há microrregiões em posições semelhantes nos diferentes índices, mas que eles não são exatamente iguais. Além disso, os máximos e mínimos do ICE^V são mais extremos, indicando que esse índice possui uma maior dispersão. Isso é visualmente perceptível nos mapas do Figura 3, nos quais verifica-se uma menor quantidade de microrregiões com cores das extremidades da escala no índice, e mais regiões com cores intermediárias.

Figura 3. Mapas dos índices, por microrregiões (2019)



Fonte: Elaboração própria a partir de dados do CNPJ/RFB, da RAIS e do IBGE.

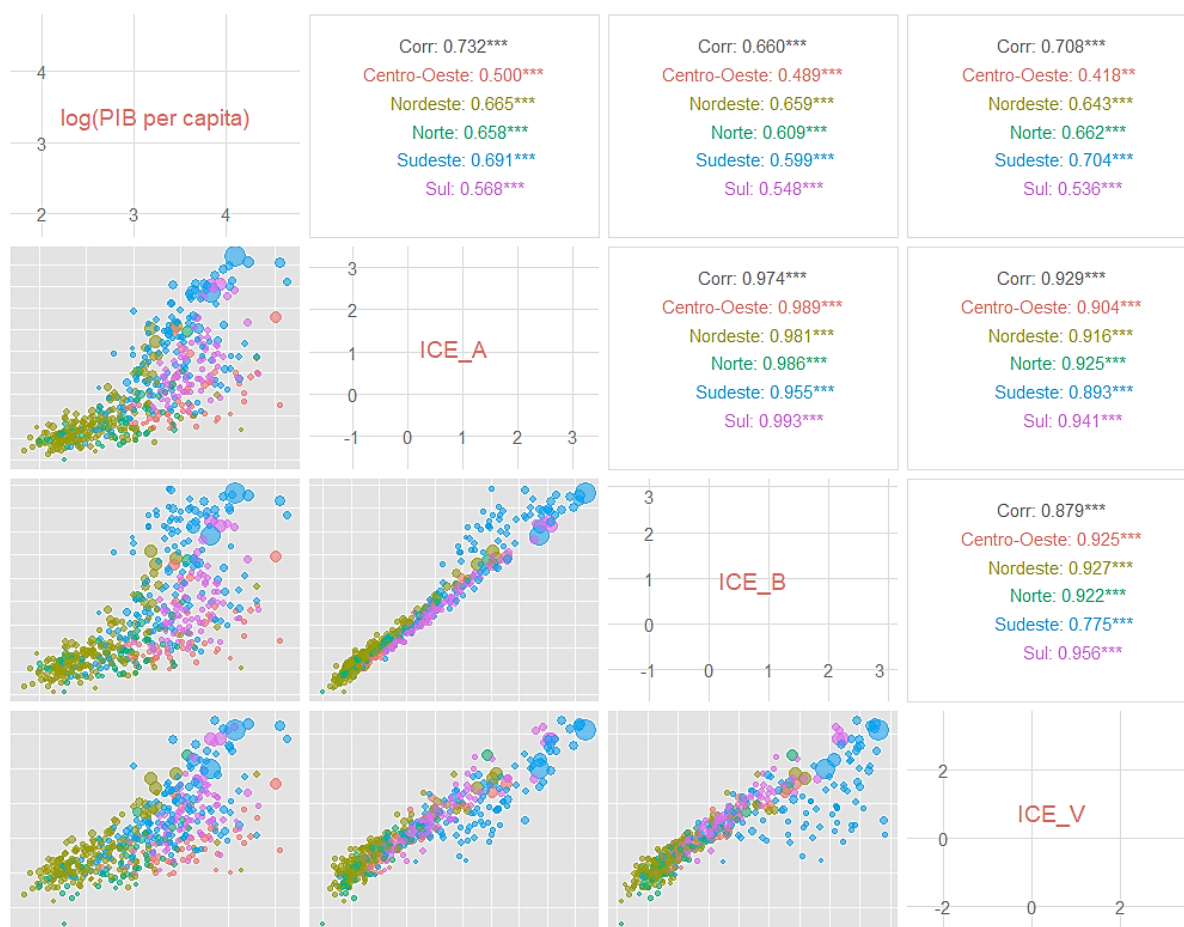
* Nota: As escalas dos três índices são independentes entre si, de forma que as cores mais extremas estejam sempre atribuídas aos máximos e mínimos de cada índice, sem que um interfira no outro.

É interessante explorar também as correlações dos três índices entre si e com o PIB *per capita*. O Gráfico 4, que usa dados apenas de 2019, mostra que o ICE^A e o ICE^B são muito próximos, com correlação de 0,97. Com o ICE^V , os índices A e B possuem respectivamente correlações de 0,92 e 0,87. Nota-se que os três índices também estão altamente correlacionados com o PIB *per capita*, com correlações de 0,73, 0,66 e 0,70 para o ano de 2019.

Tabela 1. Microrregiões com maiores e menores índices


#	ICE ^A			ICE ^B			ICE ^V		
	UF	Microrregião	Valor	UF	Microrregião	Valor	UF	Microrregião	Valor
1	SP	São Paulo	3,20	SP	Jales	2,91	SP	Guarulhos	3,36
2	SP	Campinas	3,08	SP	Presidente Prudente	2,88	SP	Campinas	3,26
3	SP	Osasco	3,06	SP	São Paulo	2,81	SP	Osasco	3,22
4	SP	São José dos Campos	2,97	SP	Piracicaba	2,77	SC	Joinville	3,19
5	SP	Sorocaba	2,91	SP	Campinas	2,76	SP	Sorocaba	3,12
6	SP	Guarulhos	2,76	SP	Sorocaba	2,75	RS	Caxias do Sul	3,08
7	SP	Piracicaba	2,66	SP	Araraquara	2,68	SP	São Paulo	3,07
8	SP	Jundiá	2,63	SP	Osasco	2,67	PR	Curitiba	2,87
9	SP	Itapecerica da Serra	2,58	SP	Ribeirão Preto	2,64	SP	Jundiá	2,83
10	SP	Ribeirão Preto	2,56	SP	Votuporanga	2,54	RS	Porto Alegre	2,83
549	PI	Chapadas do Extremo Sul Piauiense	-1,24	MA	Gurupi	-1,22	MA	Baixo Parnaíba Maranhense	-1,44
550	AL	Batalha	-1,24	AM	Juruá	-1,24	RR	Caracará	-1,44
551	PB	Curimataú Oriental	-1,26	RN	Serra de São Miguel	-1,24	AL	Serrana do Sertão Alagoano	-1,45
552	BA	Jeremoabo	-1,28	PI	Chapadas do Extremo Sul Piauiense	-1,24	MG	Grão Mogol	-1,49
553	PI	Médio Parnaíba Piauiense	-1,29	MA	Baixo Parnaíba Maranhense	-1,25	PA	Portel	-1,58
554	MA	Litoral Ocidental Maranhense	-1,30	MA	Litoral Ocidental Maranhense	-1,31	MA	Litoral Ocidental Maranhense	-1,61
555	PB	Serra do Teixeira	-1,30	AL	Serrana do Sertão Alagoano	-1,32	AM	Boca do Acre	-1,63
556	PI	Bertolínia	-1,31	PI	Bertolínia	-1,37	AM	Purus	-1,71
557	AL	Serrana do Sertão Alagoano	-1,38	AM	Japurá	-1,43	AL	Traipu	-1,81
558	M	Japurá	-1,51	AL	Traipu	-1,43	AM	Japurá	-2,46

Fonte: Elaboração própria a partir de dados do CNPJ/RFB, da RAIS e do IBGE.

Figura 4. Correlações dos ICE entre si e com o PIB *per capita*

Fonte: Elaboração própria a partir de dados do CNPJ/RFB, da RAIS e do IBGE. Dados de 2019. As bolhas representam as microrregiões e seu tamanho é proporcional à população.

A evolução das correlações de cada índice com o PIB *per capita* ao longo do período estudado sugere que elas eram mais intensas no início da série. O Figura 5 mostra que as correlações do ICE^A e do ICE^V com o PIB *per capita* permanecem próximas, enquanto a correlação entre ICE^B e PIB *per capita* apresenta tendência de queda. Uma das hipóteses para explicar essa situação é a perda de informação no ICE^B pelo fato de este não incluir dados do MEI, atualmente a categoria mais numerosa de CNPJs empresariais.

Figura 5. Evolução da correlação de cada índice com o PIB *per capita*

Fonte: Elaboração própria a partir de dados do CNPJ/RFB, da RAIS e do IBGE.

5. Resultados das regressões

5.1 Regressão em MQO

Foram estimados seis modelos: um para cada um dos três índices, realizados com e sem as variáveis de controle (população inicial e expectativa de anos de estudo inicial). Os resultados na Tabela 2 revelam que o PIB *per capita* inicial, como esperado, obteve coeficientes negativos, indicativo do efeito de convergência (*catching-up*), ou seja, microrregiões menos desenvolvidas tendem a crescer a taxas mais rápidas que as mais desenvolvidas.

Em relação às variáveis de interesse deste trabalho, os três índices de complexidade econômica apresentaram significância estatística em todos os modelos. Nos modelos sem as variáveis de controle, ICE^A e ICE^V apresentaram p-valor e coeficientes próximos e ligeiramente melhores que o ICE^B . Como esperado, a inclusão dos controles melhorou o ajuste do modelo e reduziu a significância dos índices. Ainda assim, os coeficientes estimados para os índices se mantiveram estatisticamente significantes

Provavelmente, existem características não observáveis das microrregiões que contribuem, ao mesmo tempo, para a complexidade e para o crescimento econômico. Isso reforça a necessidade da análise via painel de dados, que pode controlar esses efeitos não observáveis.

Tabela 2. Modelos MQO

	Variável dependente: ΔY_i (variação do PIB per capita)					
	Modelos sem Controles			Modelos com Controles		
	ICE^A (empresas, inclui MEI)	ICE^B (empresas, exclui MEI)	ICE^V (vínculos empregatícios)	ICE^A (empresas, inclui MEI)	ICE^B (empresas, exclui MEI)	ICE^V (vínculos empregatícios)
(Intercepto)	0.757*** (<0.001)	0.744*** (<0.001)	0.761*** (<0.001)	-0.548+ (0.099)	-0.602+ (0.069)	-0.420 (0.183)
$\log(\text{PIB per capita inicial})$	-0.228*** (<0.001)	-0.224*** (<0.001)	-0.228*** (<0.001)	-0.265*** (<0.001)	-0.261*** (<0.001)	-0.275*** (<0.001)
$\Delta V A_{AGRO}$	0.149*** (<0.001)	0.148*** (<0.001)	0.152*** (<0.001)	0.174*** (<0.001)	0.174*** (<0.001)	0.178*** (<0.001)
$\Delta V A_{PUB}$	0.222*** (<0.001)	0.219*** (<0.001)	0.202*** (<0.001)	0.294*** (<0.001)	0.292*** (<0.001)	0.285*** (<0.001)
$ICE_{i,5y}^A$ (média dos 5 anos iniciais)	0.044** (<0.001)	-	-	0.041* (0.028)	-	-
$ICE_{i,5y}^B$ (média dos 5 anos iniciais)	-	0.040** (0.003)	-	-	0.037* (0.048)	-
$ICE_{i,5y}^V$ (média dos 5 anos iniciais)	-	-	0.044*** (<0.001)	-	-	0.054** (0.002)
$\log(\text{População Inicial})$	-	-	-	-0.031* (0.023)	-0.029* (0.034)	-0.038** (0.004)
$\log(\text{Expectativa de Anos de Estudo})$	-	-	-	0.791*** (<0.001)	0.802*** (<0.001)	0.790*** (<0.001)
Num. Obs.	534	534	534	534	534	534
R ²	0.326	0.324	0.327	0.398	0.397	0.403
R ² Adj.	0.321	0.319	0.322	0.391	0.390	0.396

Notas: + p < 0.1, * p < 0.05, ** p < 0.01, *** p < 0.001. Valores-p entre parênteses.
Fonte: Elaboração própria

5.2 Regressão em painel de dados

Os resultados do painel de dados com efeitos fixos mostram apenas o ICE^A com significância estatística (Tabela 3). Os demais índices não alcançaram significância, o que indica que os efeitos da complexidade econômica sobre o PIB *per capita* medidos pelos índices ICE^B e ICE^V podem não estar sendo captados pelas variações de apenas um ano.

Uma hipótese para explicar o melhor desempenho do ICE^A no curto prazo é o MEI. A agilidade para abertura e encerramento de um CNPJ do porte MEI, feita *online* para a maior parte das atividades econômicas, pode ter contribuído para essa melhor reação às questões de curto prazo. Já o ICE^B inclui empresas de porte maior que o MEI, com processos de abertura e fechamento mais complicados e que levam mais tempo. O ICE^V , calculado com dados do universo de empregos, apesar de provavelmente responder rápido em momentos de crise por conta das reduções nos postos de trabalho, deve ter resposta mais lenta no pós-crise pela maior dificuldade no retorno das vagas. Portanto, o período de recessão no país a partir de 2015 pode ter impactado negativamente o desempenho do ICE^V neste modelo.

Tabela 3. Modelos em painel

	Variável dependente: $\log(Y_{i,t}) - \log(Y_{i,t-1})$		
	ICE^A (empresas, inclui MEI)	ICE^B (empresas, exclui MEI)	ICE^V (vínculos empregatícios)
$\log(Y_{i,t-1})$	-0.259*** (<0.001)	-0.257*** (<0.001)	-0.257*** (<0.001)
$\log(VA_{i,t}^{AGRO}) - \log(VA_{i,t-1}^{AGRO})$	0.157*** (<0.001)	0.157*** (<0.001)	0.157*** (<0.001)
$\log(VA_{i,t}^{PUB}) - \log(VA_{i,t-1}^{PUB})$	0.286*** (<0.001)	0.288*** (<0.001)	0.288*** (<0.001)
$ICE_{i,t-1}^A$	0.023* (0.016)	-	-
$ICE_{i,t-1}^B$	-	0.002 (0.818)	-
$ICE_{i,t-1}^V$	-	-	0.006 (0.353)
Num.Obs.	5874	5874	5874
R ²	0.342	0.341	0.341
R ² Adj.	0.274	0.273	0.273

Notas: + p < 0.1, * p < 0.05, ** p < 0.01, *** p < 0.001. Valores-p entre parênteses.

Para confirmar a escolha pelo tipo de painel com efeitos fixos, as mesmas variáveis foram utilizadas para estimar modelos em painel com dados empilhados e com efeitos aleatórios.

A comparação entre dados empilhados e efeitos fixos foi feita por meio do Teste F. A hipótese nula é que interceptos e coeficientes angulares são iguais para todos os indivíduos, o que determinaria a escolha pelo modelo com dados empilhados. Os resultados para os modelos dos três índices rejeitam a hipótese nula e, portanto, a opção pelos efeitos fixos.

Já a comparação entre modelo de efeitos fixos e efeitos aleatórios utilizou o Teste de Hausman para modelos em painel. Também foi rejeitada a hipótese nula para os três índices, dando preferência ao modelo com efeitos fixos.

Tabela 4. Teste F para efeitos individuais e temporais

	ICE^A (empresas, inclui MEI)	ICE^B (empresas, exclui MEI)	ICE^V (vínculos empregatícios)
Estatística F	4.0012	4.0225	4.0288
Valor-p	< 2.2e-16	< 2.2e-16	< 2.2e-16
df1	543	543	543
df2	5326	5326	5326

Fonte: Elaboração própria.

Tabela 5. Teste de Hausman

	ICE^A (empresas, inclui MEI)	ICE^B (empresas, exclui MEI)	ICE^V (vínculos empregatícios)
Chisq	685.35	692.44	693.45
Valor-p	< 2.2e-16	< 2.2e-16	< 2.2e-16
df	4	4	4

Fonte: Elaboração própria.

6. Testes de robustez

6.1 Período do ICE utilizado na regressão MQO

Na regressão MQO, optou-se por utilizar, para cada microrregião, a média de seu ICE dos 5 primeiros anos do período em análise, como forma de suavizar possíveis variações. Para verificar se os resultados se confirmam caso sejam escolhidos outros períodos, os modelos foram estimados novamente utilizando a média do ICE dos 3 primeiros anos e de anos individualmente (2008, 2010 e 2012). Os modelos para este teste utilizaram todas as variáveis do modelo principal, incluindo as variáveis de controle.

De maneira geral, os três índices mantiveram-se significantes nos períodos testados, com exceção apenas do ICE^A e do ICE^B no ano de 2010, os únicos que ficaram ligeiramente acima do nível de 5%.

Tabela 6. Modelos MQO com ICE's de diferentes períodos

	Modelos com ICE 2008			Modelos com ICE 2010		
	ICE^A	ICE^B	ICE^V	ICE^A	ICE^B	ICE^V
Coefficiente	0.041*	0.041*	0.045*	0.034+	0.034+	0.048**
Valor-p	(0.031)	(0.031)	(0.010)	(0.066)	(0.065)	(0.005)
	Modelos com ICE 2012			Modelos com ICE médio de 3 anos		
	ICE^A	ICE^B	ICE^V	ICE^A	ICE^B	ICE^V
Coefficiente	0.046**	0.035*	0.058***	0.037*	0.037*	0.050**
Valor-p	(0.010)	(0.047)	(<0.001)	(0.048)	(0.048)	(0.004)

Notas: + $p < 0.1$, * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$. Valores-p entre parênteses.

6.2 Outliers

A análise exploratória das variações anuais dos três índices e do PIB *per capita* revelou algumas microrregiões com variações muito extremas nessas variáveis. Nas regressões principais deste estudo, optou-se por retirar as microrregiões que apresentaram, em qualquer momento da série, variações anuais para além de 10 desvios-padrão da média, para mais ou para menos. Com esse corte, 24 microrregiões foram retiradas, razão pela qual a regressão de MQO mostra o número de 534 observações.

Para fins de robustez da análise, os modelos foram estimados novamente sem essa exclusão, considerando todas as 558 microrregiões. Tanto na regressão de MQO quanto na regressão com dados em painel, os três índices alcançaram os mesmos resultados obtidos previamente, conforme Tabelas 7 e 8 a seguir. Nos modelos que mantêm os *outliers*, houve ligeiro aumento nos coeficientes e na significância estatística dos índices.

Tabela 7. Modelos MQO sem exclusão de outliers

	Variável dependente: ΔY_i (variação do PIB <i>per capita</i>)		
	ICE^A (empresas, inclui MEI)	ICE^B (empresas, exclui MEI)	ICE^V (vínculos empregatícios)
(Intercepto)	0.193 (0.707)	0.172 (0.737)	0.271 (0.577)
log(PIB <i>per capita</i> inicial)	-0.276*** (<0.001)	-0.275*** (<0.001)	-0.285*** (<0.001)
ΔVA^{AGRO}	0.127*** (<0.001)	0.126*** (<0.001)	0.132*** (<0.001)
ΔVA^{PUB}	0.384*** (<0.001)	0.386*** (<0.001)	0.363*** (<0.001)
$ICE_{i,5y}^A$ (média dos 5 anos iniciais)	0.067* (0.019)	-	-
$ICE_{i,5y}^B$ (média dos 5 anos iniciais)	-	0.066* (0.021)	-
$ICE_{i,5y}^V$ (média dos 5 anos iniciais)	-	-	0.078** (0.004)
log(População Inicial)	-0.065** (0.001)	-0.065** (0.002)	-0.072*** (<0.001)
log(Expectativa de Anos de Estudo)	0.660*** (<0.001)	0.668*** (<0.001)	0.675*** (<0.001)
Num. Obs.	558	558	558
R ²	0.215	0.214	0.219
R ² Adj.	0.206	0.206	0.210

Notas: + p < 0.1, * p < 0.05, ** p < 0.01, *** p < 0.001. Valores-p entre parênteses.

Tabela 8. Modelos em painel sem exclusão de outliers

	Variável dependente: $\log(Y_{i,t}) - \log(Y_{i,t-1})$		
	ICE^A (empresas, inclui MEI)	ICE^B (empresas, exclui MEI)	ICE^V (vínculos empregatícios)
log($Y_{i,t-1}$)	-0.272*** (<0.001)	-0.270*** (<0.001)	-0.271*** (<0.001)
log($VA_{i,t}^{AGRO}$) - log($VA_{i,t-1}^{AGRO}$)	0.164*** (<0.001)	0.164*** (<0.001)	0.164*** (<0.001)
log($VA_{i,t}^{PUB}$) - log($VA_{i,t-1}^{PUB}$)	0.256*** (<0.001)	0.258*** (<0.001)	0.258*** (<0.001)
$ICE_{i,t-1}^A$	0.027* (0.011)	-	-
$ICE_{i,t-1}^B$	-	-0.0003 (0.976)	-
$ICE_{i,t-1}^V$	-	-	0.008 (0.277)
Num.Obs.	6138	6138	6138
R ²	0.317	0.316	0.316
R ² Adj.	0.247	0.246	0.246

Notas: + p < 0.1, * p < 0.05, ** p < 0.01, *** p < 0.001. Valores-p entre parênteses.

7. Conclusão

O propósito deste trabalho foi avaliar o impacto da complexidade local no crescimento econômico regional brasileiro entre 2008 e 2019, utilizando dados até então não explorados que incluem todos os portes empresariais, em especial os MEI e as pequenas empresas sem empregados. Nesse sentido, foram calculados três índices de complexidade com bases de dados distintas: ICE^A (empresas, incluindo MEI), ICE^B (empresas, exceto MEI), ICE^V (apenas vínculos empregatícios) que serviram de ponto de partida para a análise.

Este artigo faz contribuições importantes para a literatura sobre complexidade econômica ao incluir os microempreendedores individuais (MEI) e as pequenas empresas sem empregados no cálculo dos índices de complexidade. Os MEI se tornaram a categoria mais numerosa entre os portes empresariais no Brasil e, portanto, sua inclusão resulta em indicadores mais representativos da estrutura produtiva, especialmente em regiões menores e menos desenvolvidas. Assim, o artigo preenche uma lacuna na literatura ao ampliar a abrangência da metodologia da complexidade econômica para um grupo de empresas essencial, mas até então negligenciado. Com isso, abrem-se novas perspectivas para o debate, destacando a relevância de incluir os MEI e os pequenos negócios para aprimorar a mensuração da complexidade produtiva e o desenho de políticas de desenvolvimento regional.

É importante ser cauteloso ao interpretar os resultados obtidos, uma vez que a estimação do impacto da complexidade depende de escolhas metodológicas específicas no cálculo dos índices ICE. Ademais, tanto na estimação *cross-section* quanto nos dados de painel, trata-se de um período relativamente curto e peculiar na economia brasileira. Além disso, há outras fontes de incerteza nos resultados: a agregação no nível da microrregião e nas classes da CNAE oculta heterogeneidades espaciais e setoriais. Caso esses níveis de agregação sejam alterados, talvez as conclusões deste estudo não se mantenham. Por fim, o efeito do MEI por formalização ou *pejotização* não é distinguível nos dados e pode viesar as estimativas. Por esses motivos, seria imprudente utilizar esses resultados isoladamente para guiar o desenho de políticas públicas ou mesmo inferir recomendações gerais de políticas públicas.

Por fim, espera-se que este estudo possa estimular outras pesquisas que abordem a importância dos MEI e das pequenas empresas sem empregados nos debates sobre desenvolvimento regional. Não há razão teórica ou empírica para que isso não seja feito.

Referências

- Balassa, B. (1965). Trade liberalisation and “revealed” comparative advantage. *The Manchester School*, 33(2):99–123.
- Balland, P., Jara-Figueroa, C., Petralia, S., Steijn, M., Rigby, D., e Hidalgo, C. (2018).

- Complex economic activities concentrate in large cities. *Papers in Evolutionary Economic Geography (PEEG)*, (1829).
- Brasil (2019). Cadastro nacional da pessoa jurídica (cnpj). Base pública de 28/05/2020 disponibilizada por <https://github.com/georgevbsantiago/qsacnpj> (Accessed: 30 August 2022).
- Carvalho, D. E., Stein, A. Q., Queiroz, A., e Romero, J. P. (2022). Complexidade econômica e crescimento do pib per capita: uma análise de diferenças-em-diferenças para os municípios brasileiros. In: *Anais do 50º Encontro Nacional de Economia*, Fortaleza/CE.
- Cimini, F., Porto, I., e Rocha, E. (2018). Encurtando as distâncias: o uso da plataforma dataviva para identificar oportunidades de sofisticação econômica em minas gerais. *Revista de Economia Contemporânea*, 21(3):1–31.
- Corseuil, C. H. L., Neri, M. C., e Ulyseia, G. (2014). Uma análise exploratória dos efeitos da política de formalização dos microempreendedores individuais. Texto para Discussão 1939, Instituto de Pesquisa Econômica Aplicada (IPEA), Brasília.
- DataViva (2017). Dataviva: Rankings. Available at <http://dataviva.info/pt/rankings/> (Accessed: 13 March 2022).
- Fagundes, M. B. B., Silva Júnior, E. d. A., Figueiredo, A. M. R., e Machado, J. V. (2019). Complexidade econômica regional: Uma abordagem a partir de dados de emprego. *RDE-Revista de Desenvolvimento Econômico*, 2(43).
- Freitas, E. (2019). *Indústrias relacionadas, complexidade econômica e diversificação regional: uma aplicação para microrregiões brasileiras*. Tese de Doutorado, Universidade Federal de Minas Gerais, Belo Horizonte.
- Gao, J., Jun, B., Pentland, A., Zhou, T., e Hidalgo, C. (2021). Spillovers across industries and regions in china's regional economic diversification. *Regional Studies*, 55(7):1311–1326.
- Garcez, L. C., Arend, M., e Giovanini, A. (2019). Complexidade econômica e desequilíbrios regionais em santa catarina. *Textos de Economia*, 22(1):04–31.
- Hartmann, D., Guevara, M. R., Jara-Figueroa, C., Aristarán, M., e Hidalgo, C. A. (2017). Linking economic complexity, institutions, and income inequality. *World development*, 93:75–93.
- Hausmann, R., C., H., Bustos, S., Coscia, M., Simões, A., e Yildirim, M. (2013). *The Atlas of Economic Complexity - Mapping Paths to Prosperity*. The MIT Press, Cambridge, MA.
- Hausmann, R. e Chauvin, J. (2015). Moving to the adjacent possible: Discovering paths for export diversification in rwanda. *CID Working Paper Series*.

- Hidalgo, C. (2021). Economic complexity theory and applications. *Nature Reviews Physics*, 3(2):92–113.
- Hidalgo, C. e Hausmann, R. (2009). The building blocks of economic complexity. *Proceedings of the National Academy of Sciences*, 106(26):10570–10575.
- Hidalgo, C., Klinger, B., Barabasi, A.-L., e Hausmann, R. (2007). The product space conditions the development of nations. *Science*, 317(5837):482–487.
- IBGE (2019a). Estimativas da população residente nos municípios brasileiros com data de referência em 1º de julho – 2008 a 2019. Available at <https://www.ibge.gov.br/estatisticas/sociais/populacao/9103-estimativas-de-populacao.html> (Accessed: 30 August 2022).
- IBGE (2019b). Pib dos municípios 2008-2019. Available at <https://www.ibge.gov.br/estatisticas/economicas/contas-nacionais/9088-produto-interno-bruto-dos-municipios.html> (Accessed: 30 August 2022).
- Medeiros, R. L., Gala, P. S. d. O. S., Faria, L. H. L., e Teixeira, R. B. (2020). Economic complexity and post-pandemic challenges for brazil: A new perspective for espírito santo. *RINTERPAP-Revista Interdisciplinar de Pesquisas Aplicadas*, 1(1):1–11.
- PNUD (2013). Atlas do desenvolvimento humano no brasil. Available at <http://www.atlasbrasil.org.br/acervo/biblioteca> (Accessed: 08 September 2022).
- Queiroz, A. R., Romero, J. P., e Freitas, E. (2023). Economic complexity and employment in brazilian states. *CEPAL Review*, (123):177–196.
- RAIS (2019). Relação anual de informações sociais (rais). Bases de 2008 a 2019. Disponível em <ftp://ftp.mtps.gov.br/pdet/microdados/RAIS/> (Accessed: 30 August 2022).
- Romero e Silveira, F. (2019). Mudança estrutural e complexidade econômica: identificando setores promissores para o desenvolvimento dos estados brasileiros. *Alternativas para o desenvolvimento brasileiro: novos horizontes para a mudança estrutural com igualdade*. Santiago: CEPAL, 2019. LC/TS. 2019/27 LC/BRS/TS. 2019/3 p. 137-160.
- Romero, J. e Gramkow, C. (2021). Economic complexity and greenhouse gas emissions. *World Development*, 139:105317.
- SEBRAE – Serviço Brasileiro de Apoio às Micro e Pequenas Empresas (2019). Relatório especial mei 10 anos. Available at <datasebrae.com.br/perfil-do-microempreendedor-individual> (Accessed: 06 November 2022).
- SEBRAE – Serviço Brasileiro de Apoio às Micro e Pequenas Empresas (2022). Pesquisa perfil do mei. Available at <datasebrae.com.br/perfil-do-microempreendedor-individual> (Accessed: 06 November 2022).

Vargas, M. (2020). *economiccomplexity*: Computational methods for economic complexity. R package version 1.1. Available at <https://CRAN.R-project.org/package=economiccomplexity> (Accessed: 07 August 2022).

 Este artigo está licenciado com uma *CC BY 4.0 license*.