

UNIVERSIDADE DE SÃO PAULO
FACULDADE DE ECONOMIA, ADMINISTRAÇÃO, CONTABILIDADE E ATUÁRIA
DEPARTAMENTO DE ECONOMIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA

HABILIDADES DOS TRABALHADORES NA INDÚSTRIA BRASILEIRA

Gustavo Henrique Leite de Castro

Orientador: Prof. Dr. Carlos Roberto Azzoni

SÃO PAULO

2023

Prof. Dr. Carlos Gilberto Carlotti Junior
Reitor da Universidade de São Paulo

Prof. Dra. Maria Dolores Montoya Diaz
Diretor da Faculdade de Economia, Administração, Contabilidade e Atuária

Prof. Dr. Claudio Ribeiro de Lucinda
Chefe do Departamento de Economia

Prof. Dr. Mauro Rodrigues Junior
Coordenador do Programa de Pós-Graduação em Economia

GUSTAVO HENRIQUE LEITE DE CASTRO

HABILIDADES DOS TRABALHADORES NA INDÚSTRIA BRASILEIRA

Tese apresentada ao Programa de Pós-Graduação em Economia do Departamento de Economia da Faculdade de Economia, Administração, Contabilidade e Atuária da Universidade de São Paulo, como requisito parcial para a obtenção do título de Doutor em Ciências.

Orientador: Prof. Dr. Carlos Roberto Azzoni

Versão Corrigida

(versão original disponível na Biblioteca da Faculdade de Economia, Administração, Contabilidade e Atuária)

SÃO PAULO

2023

Catálogo na Publicação (CIP)
Ficha Catalográfica com dados inseridos pelo autor

Castro, Gustavo Henrique Leite de
Habilidades dos trabalhadores na indústria brasileira / Gustavo Henrique
Leite de Castro. – São Paulo, 2023.
226 p.

Tese (Doutorado) – Universidade de São Paulo, 2023.
Orientador: Carlos Roberto Azzoni.

1. Economia Regional. 2. Econometria Espacial. 3. Indústrias
4. Desenvolvimento Econômico. Universidade de São Paulo.
Faculdade de Economia, Administração, Contabilidade e Atuária. II. Título.

A Deus, que fez brotar no santuário da
minha alma o amor e o perdão.
À minha família.

AGRADECIMENTOS

Primeiramente agradeço a Deus, que me despertou para uma nova vida, sendo minha força e sustento, fazendo-me acreditar ainda mais no poder da fé e oração.

Agradeço à minha família pelo apoio incondicional: minha mãe, pelas orações; meu pai, pela motivação, e aos meus irmãos que, de uma forma ou de outra, sempre estiveram comigo. Meu amor por vocês é incondicional. Agradeço também às famílias Castro, Leite, Polido e Casagrande por todo suporte e incentivo.

Ao professor Carlos R. Azzoni, pelo apoio, suporte, ajudas que foram despendidas, às discussões técnicas e estímulos a prosseguir em frente. Além de um excelente profissional, foi capaz de tornar o ambiente agradável tanto ao aprendizado como à produção acadêmica. Por meio da simplicidade, do ensino, trabalho, dedicação e competência, me fez enxergar o quão importante é ter princípios e valores em um mundo carente de bons exemplos. Os agradecimentos também se estendem aos professores do NEREUS, por contribuições e ideias relevantes, não apenas nessa tese, mas em outras pesquisas, seja durante os Encontros Semanais no NEREUS, seja em seus escritórios. Especialmente, agradeço aos professores André S. Chagas, pela coorientação desta tese e por suas sugestões e apontamentos técnicos, e Eduardo A. Haddad, pelo incentivo, contribuindo positivamente com ideias e direcionamento desta pesquisa.

Estendo os agradecimentos aos Professores que me ajudaram nessa jornada, em especial ao Prof. Gilberto Tadeu Lima que, sem sombra de dúvidas, foi um dos melhores Professores que eu já tive. Não posso deixar de agradecer aos meus colegas, as grandes amizades que fiz durante o doutorado. Graças à ajuda deles eu consegui concluir esse objetivo. Dentre esses, meu sincero agradecimento a Pedro Henrique Batista Barros pela recorrente disponibilidade em ajudar e discutir questões inerentes às disciplinas, a introdução ao *machine learning* e a este trabalho e a Inácio Fernandes de Araújo Junior, por sua capacidade cooperativa e por compartilhar seu conhecimento, dispondo sempre do seu tempo. Da mesma forma, agradeço a disposição de Keyi Ussami em sempre cooperar com seu conhecimento, principalmente na introdução aos microdados e à utilização do servidor. Aos amigos Rodger Barros Antunes Campos, Luís Abel Silva Filho e Bruno Volsi, muito obrigado pelas sugestões e incentivos. Não posso me furtar de agradecer ao amigo Mateus Rodrigues pelo suporte na programação dos microdados da RAIS e tantas outras dúvidas em relação à programação e à base de dados.

Agradeço também pelo suporte financeiro da Fundação Instituto de Pesquisa Econômicas (Fipe). Não posso deixar de agradecer ao pessoal da secretária da pós-graduação por toda atenção prestada nesses últimos quatro anos.

“Thus, the task is not so much to see what no one yet has seen, but to think what nobody yet has thought about that which everybody sees.”

Arthur Schopenhauer
1788-1860

RESUMO

A capacidade de uma região crescer no longo prazo está relacionada, dentre outros fatores, ao desempenho da indústria. Este último depende da sua capacidade em aumentar a produção por trabalhador. A explicação para as diferenças de produtividade e de crescimento econômico nos espaços geográficos reside nas diferenças de capital humano entre eles e, em particular, nas diferenças de capital humano na indústria. O tema central desta tese é a análise da sofisticação da produção industrial regional a partir das habilidades requeridas nas ocupações envolvidas no processo produtivo. O foco é o capital humano, analisado a partir das habilidades requeridas pela indústria de transformação nas regiões brasileiras. A justificativa reside nas evidências de que a indústria está passando por um processo de desconcentração regional no Brasil. Porém pouco se sabe a respeito da dinâmica das habilidades requeridas dos trabalhadores para o exercício das ocupações. O objetivo do estudo é verificar se há convergência por habilidades na indústria de transformação, ou seja, se as regiões que possuíam menor sofisticação industrial se tornaram mais sofisticadas. O estudo se utiliza de modelos de convergência condicional espacial em painel de micro dados no período 2003-2019. Objetiva identificar se há correlação negativa entre o nível inicial de habilidades e a sua taxa de crescimento nas regiões, controlando os efeitos espaciais (autocorrelação e dependência espacial nos resíduos) e as características não observáveis de região e de tempo. Para o cálculo das notas de habilidades nós utilizamos a classificação elaborada por Maciente (2013), Neves (2018) e Neves, Azzoni & Chagas (2021). Foram estimadas regressões para a heterogeneidade da indústria (agroindústria, não-agroindústria, indústria intensiva em capital e indústria intensiva em trabalho) e heterogeneidade espacial utilizando classes de tamanho. Também foram estimadas regressões para a escolaridade dos trabalhadores e para a intensidade de habilidades (escolaridade x habilidades). Os resultados mostram que há convergência condicional das habilidades, porém com diferenças significativas entre os cortes de média, mediana e último quartil das habilidades, bem como para o tipo de indústria e para as classes de tamanho de região. As evidências mostram que a indústria está convergindo mais rapidamente nas habilidades sociais e cognitivas do que nas habilidades motoras. Foram realizados testes de robustez, que corroboraram as evidências encontradas. Os resultados mostram que o espaço joga um papel importante, uma vez que as regiões apresentam importantes diferenças institucionais e estruturais, impactando de forma heterogênea na convergência espacial das habilidades. Os resultados também mostram que há convergência de escolaridade e de intensidade de habilidade na indústria e para as classes de tamanho. A análise das habilidades das ocupações é uma nova forma de avaliar a dinâmica do mercado de trabalho e da complexidade da indústria instalada nas regiões brasileiras, para além dos níveis de escolaridade.

Palavras-chave: Indústria. Habilidades. Heterogeneidade espacial. Heterogeneidade regional. Escolaridade.

ABSTRACT

The ability of a region to grow in the long term is related, among other factors, to manufacturing performance. The latter depends on the ability to increase the production per worker. The explanation for the differences in productivity and economic growth in geographic spaces lies in the differences in human capital between them, particularly in manufacturing. The central theme of this dissertation is the sophistication of regional manufacturing production based on the skills of the occupations involved in the production processes. The focus is on human capital, analyzed from the demand for skills in manufacturing in the Brazilian regions. Although there is a process of regional deconcentration of manufacturing in Brazil, little is known about the dynamics of the skills (cognitive, social, and motor) required in the worker's occupations in the regions. The study's objective is to answer if there is regional convergence in the demand for manufacturing skills. Have regions that had less manufacturing sophistication in the past become more sophisticated? The study uses spatial conditional convergence panel data models for the period 2003-2019 to check for a possible negative correlation between the initial levels of skills and their growth rates, controlling for spatial effects (autocorrelation and spatial dependence in the residuals) and the unobservable characteristics of regions and time. We used the classification developed by Maciente (2013), Neves (2018), and Neves, Azzoni & Chagas (2021) to calculate the skill scores. We estimated regressions to check for sectoral heterogeneity (agribusiness, non-agribusiness, capital-intensive, and labor-intensive) and spatial heterogeneity using size clusters. We also estimated regressions for workers' education and skill intensity (education x skills). The results show conditional convergence of skills, with significant differences between the mean, median, and last quartile cuts, as well as for the type of manufacturing and the type of cluster. The evidence shows that manufacturing is converging faster on social and cognitive skills than motor skills. The robustness tests corroborated the evidence found. The results show that space plays an important role since the regions show institutional and structural differences, heterogeneously impacting the spatial convergence of skills. The results also show a convergence of education and skill intensity for the clusters. The results show that occupation skills are a new way of analyzing the dynamics of the labor market and the complexity of manufacturing installed in Brazilian regions beyond schooling levels.

Keywords: Industry. Skills. Spatial heterogeneity. Regional heterogeneity. Schooling.

LISTA DE TABELAS

Tabela 1: Emprego formal na indústria brasileira em 2003 e 2019.....	28
Tabela 2: Notas das habilidades queridas para as ocupações (CBO)	45
Tabela 3: Estatísticas Descritivas para as habilidades.....	90
Tabela 4: Estatísticas Descritivas para a escolaridade.....	93
Tabela 5: Estatísticas Descritivas para a intensidade de habilidades	103
Tabela 6: Resultado das regressões para a média das habilidades cognitivas.....	104
Tabela 7: Efeito direto, indireto e total do modelo SDM para as habilidades cognitivas	105
Tabela 8: Teste t para a convergência global das habilidades.....	108
Tabela 9: Velocidade anual implícita de convergência (φ) e Meia-Vida (anos) para as habilidades.....	109
Tabela 10: Resultado das regressões para a escolaridade.....	111
Tabela 11: Efeito direto, indireto e total da regressão espacial para escolaridade	112
Tabela 12: Velocidade anual implícita de convergência (φ) e Meia-Vida (anos) para a escolaridade	112
Tabela 13: Teste t para a convergência global das habilidades.....	114
Tabela 14: σ – Convergência e Teste de Silverman para as habilidades.....	117
Tabela 15: σ – Convergência e Teste de Silverman para a escolaridade.....	120
Tabela 16: σ – Convergência e Teste de Silverman para a intensidade de habilidades	123
Tabela 17: Teste t para a convergência das habilidades na agroindústria e não agroindústria	126
Tabela 18: Velocidade anual implícita de convergência (φ) e Meia-Vida (anos) para a agroindústria e não agroindústria	126
Tabela 19: Teste t para a convergência das habilidades para as indústrias intensivas em capital e intensivas em trabalho	128

Tabela 20: Velocidade anual implícita de convergência (ϕ) e Meia-Vida (anos) para as indústrias intensivas em capital e intensivas em trabalho.....	128
Tabela 21: Teste t para a convergência de escolaridade na agroindústria e não agroindústria	130
Tabela 22: Velocidade anual implícita de convergência (ϕ) e Meia-Vida (anos) para a escolaridade da agroindústria e não agroindústria	130
Tabela 23: Teste t para a convergência da escolaridade na indústria intensiva em capital e intensiva em trabalho	132
Tabela 24: Velocidade anual implícita de convergência (ϕ) e Meia-Vida (anos) para a escolaridade da indústria intensiva em capital e intensiva em trabalho.....	132
Tabela 25: Teste t para a convergência das intensidades de habilidades na agroindústria e não agroindústria.....	134
Tabela 26: Velocidade anual implícita de convergência (ϕ) e Meia-Vida (anos) para as intensidades de habilidades para a agroindústria e não agroindústria	135
Tabela 27: Teste t para a convergência das intensidades de habilidades na indústria intensiva em capital e intensiva em trabalho	137
Tabela 28: Velocidade anual implícita de convergência (ϕ) e Meia-Vida (anos) para as intensidades de habilidades das indústrias intensivas em capital e intensivas em trabalho...	137
Tabela 29: Quintil de emprego industrial nas RGI em 2019	140
Tabela 30: Resultado das regressões das habilidades cognitivas por classe de tamanho	142
Tabela 31: Efeito direto, indireto e total do modelo SDM para as habilidades cognitivas por classe de tamanho.....	143

LISTA DE QUADROS

Quadro 1: Atributos para as habilidades queridas para as ocupações (CBO)	44
--	----

LISTA DE FIGURAS

Figura 1: Distribuição espacial dos empregos na indústria	29
Figura 2: Distribuição espacial do emprego na indústria por quantil.....	31
Figura 3: Distribuição espacial das indústrias	32
Figura 4: Distribuição espacial das indústrias por quantil.....	33
Figura 5: Concentração dos estabelecimentos da indústria (A) e do emprego industrial (B) nas regiões em 2003 e 2019 - Índice de Gini e Curva de Lorenz	35
Figura 6: Habilidades requeridas em algumas ocupações da indústria química	46
Figura 7: Massa e curva de localização das habilidades da indústria nas RGI em 2003 e 2019	48
Figura 8: Massa de habilidades nas RGI em 2003 e 2019.....	50
Figura 9: Massa e curva de localização da escolaridade dos trabalhadores nas RGI em 2003 e 2019	51
Figura 10: Massa de escolaridade da indústria nas RGI em 2003 e 2019	52
Figura 11: Centro de gravidade econômico – habilidades e escolaridade, 510 regiões	56
Figura 12: Níveis médios de habilidades e escolaridade da indústria nas Grandes Regiões e no BR entre 2003 a 2019	58
Figura 13: Fluxograma metodológico	86
Figura 14: (A) Distribuição espacial de habilidades em 2003 e (B) níveis de habilidades e taxas de crescimento (2003 e 2019).....	92
Figura 15: (A) Distribuição espacial da escolaridade média em 2003 e (B) níveis médios de escolaridade e taxas de crescimento (2003 e 2019).....	94
Figura 16: Correlação entre escolaridades e habilidades na indústria.....	95
Figura 17: Relação entre escolaridades e habilidades na indústria (510, RGI).....	97
Figura 18: Distribuição espacial da intensidade de habilidades média	100
Figura 19: Taxas de crescimento da intensidade de habilidades (2003 e 2019).....	102

Figura 20: β -convergência das habilidades na indústria	106
Figura 21: β - convergência das intensidades de habilidades da indústria.....	114
Figura 22: Estimativa de densidade de kernel univariada (A) e gráfico de contorno (B), para as habilidades em 2003 e 2019.....	119
Figura 23: Estimativa de densidade de kernel univariada (A) e gráfico de contorno (B), para a escolaridade em 2003 e 2019	121
Figura 24: Estimativa de densidade de kernel univariada (A) e gráfico de contorno (B) para as intensidades de habilidades em 2003 e 2019	122
Figura 25: β -convergência das habilidades na agroindústria e não agroindústria	125
Figura 26: β -convergência das habilidades nas indústrias intensivas em capital e em trabalho	127
Figura 27: β -convergência da escolaridade na agroindústria e não agroindústria	129
Figura 28: β -convergência das habilidades na indústria intensiva em capital e intensiva em trabalho.....	131
Figura 29: β -convergência para as intensidades de habilidades na agroindústria e não agroindústria.....	133
Figura 30: β -convergência das habilidades na indústria intensiva em capital e intensiva em trabalho.....	136
Figura 31: Distribuição espacial do quintil de emprego da indústria em 2019.....	141
Figura 32: β -convergência das habilidades na indústria por classe de tamanho.....	144
Figura 33: β -convergência de escolaridade na indústria por classe de tamanho	147
Figura 34: β - convergência da intensidade de habilidade por classe de tamanho.....	149
Figura 35: β - convergência das habilidades, das intensidades das habilidades e da escolaridade	151

SUMÁRIO

1 INTRODUÇÃO	21
2 INDÚSTRIA, REGIÃO E HABILIDADES: UMA NOVA VISÃO.....	27
2.1 CARACTERÍSTICAS GERAIS DA INDÚSTRIA NO ESPAÇO.....	27
2.2 QUALIFICAÇÃO DA ESTRUTURA PRODUTIVA E COMPETITIVIDADE INDUSTRIAL: UMA NOVA PERSPECTIVA.....	42
3 METODOLOGIA.....	63
3.2 ESTRATÉGIA EMPÍRICA E DE IDENTIFICAÇÃO.....	64
3.3 A ABORDAGEM ESPACIAL	67
3.4 HETEROGENEIDADE SETORIAL	72
3.5 HETEROGENEIDADE ESPACIAL	74
3.5.1 Classe de tamanho via quintil de emprego da indústria	76
3.6 ESCOLHA DA MATRIZ ESPACIAL.....	76
3.7 TESTES DE ROBUSTEZ.....	78
3.8 BASE DE DADOS	80
3.9 FLUXOGRAMA METODOLÓGICO.....	84
4 RESULTADOS E DISCUSSÃO.....	90
4.1 CARACTERÍSTICAS DA AMOSTRA	90
4.2 CONVERGÊNCIA CONDICIONAL GLOBAL.....	103
4.2.1 Convergência condicional global das habilidades.....	104
4.2.2 Convergência condicional global da escolaridade.....	110
4.2.3 Convergência condicional global da intensidade das habilidades.....	113
4.2.4 Comparações dos resultados das análises de convergência condicional global	115

4.3 TESTE DE ROBUSTEZ PARA A CONVERGÊNCIA CONDICIONAL GLOBAL	116
4.3.1 Análises de robustez para a convergência condicional global das habilidades	116
4.3.2 Análises de Robustez para a convergência condicional global da escolaridade.....	120
4.3.3 Análises de Robustez para a convergência condicional global de intensidades de habilidades	121
4.4 HETEROGENEIDADE SETORIAL	123
4.4.1 Heterogeneidade setorial para as habilidades	124
4.4.2 Heterogeneidade setorial para a escolaridade	129
4.4.3 Heterogeneidade setorial para as intensidades de habilidades.....	132
4.4.4 Comparações dos resultados de convergência para a heterogeneidade setorial.....	138
4.5 HETEROGENEIDADE REGIONAL	139
4.5.1 Heterogeneidade regional para as habilidades	141
4.5.2 Heterogeneidade regional para a escolaridade.....	146
4.5.3 Heterogeneidade regional para as intensidades de habilidades	147
4.5.4 Comparações dos resultados de convergência para a heterogeneidade regional.....	150
4.6 SÍNTESE DOS PRINCIPAIS RESULTADOS	151
5. CONSIDERAÇÕES FINAIS	154
REFERÊNCIAS	159
APÊNDICE.....	174

1 INTRODUÇÃO

Os estudos acerca dos determinantes do crescimento econômico em uma determinada região identificam a qualificação dos trabalhadores como um dos fatores responsáveis para as decisões de investimento e produção das firmas (Lucas, 1988; Mankiw; Romer & Weil, 1992). As evidências empíricas reforçam esta constatação e indicam relação positiva entre o crescimento econômico e o nível de capital humano existente nas regiões (Benhabib & Spiegel, 1994; Cuaresma, Doppelhofer & Feldkircher, 2014; Pelinescu, 2015). Assim, a capacidade de uma região melhorar seu padrão de desenvolvimento no longo prazo depende, quase exclusivamente, das suas habilidades em aumentar a produção por trabalhador (Timmer, Vries & De Vries, 2015). Logo, a explicação para as diferenças de produtividade e de crescimento econômico das regiões reside em grande medida nas diferenças de capital humano entre esses espaços geográficos.

A estrutura produtiva é um fator relevante na determinação do crescimento econômico de um país (Ribeiro, McCombie & Lima, 2020). A literatura sobre a importância do setor industrial na dinâmica do crescimento econômico, ainda que associada aos estudos clássicos dos modelos de crescimento de Solow (1956), foi desenvolvida com os trabalhos de Chenery & Watanabe (1958) e Chenery (1960). Os resultados dessas pesquisas mostraram que um aumento do nível de renda per capita de uma região está associado ao aumento na participação do setor industrial na produção agregada.

Por outra perspectiva teórica, a relação entre indústria e o crescimento econômico é também apresentada nos modelos de crescimento de Kaldor¹. As evidências empíricas validam as suposições kaldorianas para diferentes economias, como as pesquisas recentes de Haraguchi, Cheng & Smeets (2017), Marconi, Reis & Araújo (2016), Cantore et al., (2017), Magacho & McCombie (2017) e Felipe, Mehta & Rhree (2018)². Tais estudos identificaram a importância da indústria para o crescimento econômico dos países. Com o avanço da ciência regional, foi possível estender essa investigação para as mais diversas regiões no mundo. A pesquisa de Guo, Dall'erba & Le Gallo (2012) investiga a relação entre indústria e crescimento econômico regional para a China. Já o estudo de Postiglione, Andreano & Benedetti (2017) fornece um esboço do modelo de crescimento liderado pelo avanço da produtividade industrial (lei de

¹ Ver Kaldor (1957; 1966; 1967; 1968).

² Pesquisas empíricas mais antigas: Rowthorn (1975), Cornwall (1976), Parikh (1978), Stoneman (1979), Marinho, Nogueira & Rosa (2002), Wells & Thirlwall (2003).

Kaldor-Verdoorn) para as regiões europeias na presença de efeitos espaciais. Para o caso brasileiro, percebe-se que estudos relacionando crescimento econômico e indústria nas regiões são incipientes. Por exemplo, Azzoni & Ferreira (1998) analisaram a competitividade da indústria em diferentes regiões brasileiras por meio do modelo de salários de eficiência de Kaldor, e as evidências indicaram uma mudança na tendência da competitividade regional, com o núcleo industrial do país mantendo sua vantagem relativa sobre as demais regiões. Carcanholo & Porsse (2016) avaliaram as leis de Kaldor para os municípios brasileiros e encontraram evidências de que a distribuição espacial dos retornos crescentes de escala tende a reforçar o padrão de desigualdade territorial da produtividade no Brasil, principalmente onde a indústria está localizada. O que os resultados regionais trazem em comum, além do papel relevante da indústria para o crescimento econômico, é que não se pode desconsiderar a dependência e a heterogeneidade espacial da indústria nas regiões brasileiras.

Alguns estudos empíricos reforçam o papel do setor secundário para o crescimento econômico para além da ótica Kaldoriana. Rodrik (2009) investiga o crescimento das economias em desenvolvimento a partir da hipótese de que maiores taxas de crescimento econômico estão atreladas aos avanços dos setores de bens comercializáveis e outros produtos não primários. Szirmai & Verspagen (2015) reexaminam o papel da manufatura como impulsionadora do crescimento nos países desenvolvidos e em desenvolvimento entre 1950 e 2005 e encontram um impacto positivo moderado da manufatura sobre o crescimento desses países. Gabriel e De Santana Ribeiro (2019) investigaram como a manufatura afeta o crescimento econômico ao longo do tempo, especialmente nos países em desenvolvimento, e encontraram evidências de que a manufatura ainda tem maior capacidade de influenciar a taxa de crescimento da renda per capita.

Os estudos apresentados mostraram o papel relevante da indústria para o crescimento econômico e que os países que avançaram economicamente nas últimas décadas possuem altas taxas de produtividade por trabalhador na indústria. No entanto, concomitante com o importante papel da indústria para o crescimento, um dos temas mais presentes na literatura internacional é a existência do fenômeno da desindustrialização.³ O fenômeno ocorre em países desenvolvidos e também nos países que ainda não alcançaram uma industrialização madura,

³ O conceito clássico de “desindustrialização” é a redução persistente da participação do emprego industrial no emprego total de um país ou região (Rowthorn & Ramaswam, 1999).

como o Brasil (Rodrik, 2016; Felipe & Mehta, 2016; Bernard; Smeets & Warzynski, 2017; Du & Xie, 2020).

Além da preocupação com processo de desindustrialização, o setor manufatureiro está passando por alterações significativas no seu processo produtivo, transformação está chamada de indústria 4.0⁴ (Frank; Dalenogare & Ayala, 2019). Com o avanço da indústria 4.0, exige-se uma evolução do papel do capital humano nos sistemas de produção, ou seja, todas as atividades de trabalho na cadeia de valor estão utilizando abordagens inteligentes (*smart working*), fundamentadas em tecnologias da informação e de comunicação (TICs) (Raguseo; Gastaldi & Neirotti, 2016; Longo, Nicoletti & Padovano, 2017; Stock et al., 2018).

Novamente, as evidências empíricas indicam relação positiva entre o nível de capital humano existente nas regiões e o crescimento da indústria e de sua produtividade (Lee, 2005; Backman, 2014; Chang, Wang & Liu, 2016; Chang & Lin, 2017). Desta forma, reformulando a ideia anterior, a capacidade de uma região crescer no longo prazo está relacionada, dentre outros fatores, ao desempenho da indústria. Este último depende da sua capacidade de aumentar a produção por trabalhador. Logo, a explicação para as diferenças de produtividade e de crescimento econômico em determinados espaços geográficos reside nas diferenças de capital humano entre as regiões e, em particular, nas diferenças de capital humano na indústria.

O grau de escolaridade é comumente utilizado na literatura para medir o grau de qualificação dos trabalhadores. Entretanto, essa variável não captura de modo completo certas habilidades mais específicas, muitas delas desenvolvidas no próprio exercício da ocupação (Castro & Azzoni, 2022). Este é o ponto central desta tese: avaliar a sofisticação da produção industrial regional a partir das habilidades das ocupações envolvidas no processo produtivo. Assim, o foco é o capital humano, mas analisado a partir da sofisticação da mão de obra utilizada pela indústria. A justificativa para este escopo, além da importância da produtividade da indústria sobre o crescimento econômico, da desindustrialização e da transição para a indústria 4.0 descrita anteriormente, reside nas evidências de que a indústria está passando por um processo de desconcentração regional no Brasil (Saboia, 2013; Sobrinho & Azzoni, 2015; Silva & Diniz, 2020, Diniz & Mendes, 2021). Regiões que possuíam menores níveis de emprego na indústria passaram a ter relativamente mais, porém pouco se sabe a respeito da dinâmica das habilidades

⁴ A indústria 4.0 foi cunhada em 2011 por uma iniciativa alemã do governo federal com universidades e empresas privadas. Foi um programa estratégico para desenvolver sistemas avançados de produção com o objetivo de aumentar a produtividade e a eficiência da indústria nacional (Kagermann; Wahlster & Helbig, 2013).

requeridas no próprio exercício das ocupações na indústria nessas regiões. Neste trabalho pretende-se responder à seguinte pergunta: as regiões que possuíam menor sofisticação industrial devido às habilidades requeridas nas ocupações se tornaram mais sofisticadas? Ou seja, há convergência de habilidades da indústria nas regiões brasileiras?

Olhar para a indústria brasileira por outra ótica além da convencional pode trazer perguntas que subsidiam pesquisas voltadas à reversão do processo de desindustrialização e seus efeitos sobre a estagnação econômica, bem como entender as transformações nas práticas laborais que a indústria 4.0 exige e a sua relação com as habilidades dos trabalhadores da indústria de transformação.

O uso de indicadores de habilidades em vez de escolaridade apresenta várias vantagens em diferentes análises. Primeiro, reflete de forma mais precisa a qualificação real das pessoas, já que nem sempre a educação formal representa suas habilidades práticas (Di Pietro & Urwin, 2006; Massing & Schneider, 2017). Além disso, os indicadores de habilidades tendem a ser melhores preditores de desempenho em contextos como contratação e avaliação, uma vez que estão diretamente ligados à capacidade de realizar tarefas específicas (Unger et al., 2011; Motowidlo, Borman & Schmit, 2017). Em áreas técnicas, as habilidades práticas podem ser mais cruciais do que a educação formal (Cadman & Brewer, 2001). Esses indicadores também são mais flexíveis para se adaptar a mudanças em um mundo em constante evolução (LePine, Colquitt & Erez, 2006) e reduzem viés educacional, proporcionando uma avaliação mais justa das capacidades individuais (LePine, Colquitt & Erez, 2006; Ng & Feldman, 2010; Hanushek & Woessmann, 2011). Em estudos internacionais, eles são mais úteis devido às variações nas estruturas educacionais (Hanushek & Woessmann, 2011). No entanto, é importante notar que a escolaridade ainda é relevante e uma abordagem equilibrada que considere ambos os indicadores pode ser necessária, dependendo do contexto específico.

Além disso, as habilidades requeridas nas ocupações da indústria podem variar a depender das características do mercado de trabalho nas regiões onde há ou não a concentração de emprego e do tipo de indústria localizada nessas regiões. Desta forma, o espaço joga um papel importante, uma vez que as regiões apresentam importantes diferenças institucionais e estruturais em suas escalas econômicas, mercado de trabalho e infraestrutura, que podem impactar de forma heterogênea a demanda por habilidades requeridas nas ocupações industriais e, conseqüentemente, impactar a convergência das habilidades.

Os resultados desta tese indicam, com base na realização de uma série de testes empíricos, que há convergência condicional global de habilidades na indústria, porém com diferenças significativas entre os cortes de média, mediana e último quartil das habilidades. Para a média e mediana, a velocidade é maior para as habilidades sociais e motoras; já para a análise do último quartil, a velocidade é maior para as habilidades cognitivas e sociais. Além disso, quando se analisa a convergência condicional global por grupos de indústria, os resultados são heterogêneos quanto ao tipo de indústria. Já os resultados da heterogeneidade espacial mostram evidências de que as regiões menos industrializadas estão convergindo dentro das suas classes de tamanhos com velocidades maiores para as habilidades sociais, seguidas das motoras e das cognitivas. Entretanto, as regiões mais industrializadas não estão convergindo dentro das suas classes de tamanhos para as habilidades sociais. A contribuição desta tese está em olhar para as habilidades das ocupações como uma nova forma de avaliar a dinâmica do mercado de trabalho e da sofisticação da indústria instalada nas regiões brasileiras, além das métricas comuns, como os níveis de escolaridade.

Além desta introdução, esta tese é composta por mais quatro capítulos. O segundo capítulo apresenta uma revisão de literatura sobre a indústria nas regiões brasileiras e introduz o conceito de sofisticação produtiva por meio das habilidades dos trabalhadores da indústria. O terceiro capítulo apresenta a metodologia da pesquisa, incluindo a equação de convergência condicional global e regional, o banco de dados, a estratégia de identificação, os métodos de estimação econométrica espacial utilizados e os testes de robustez. O capítulo quatro analisa as estatísticas descritivas da amostra utilizadas e os resultados encontrados neste estudo. Por fim, o capítulo cinco apresenta as considerações finais desta tese.

2 INDÚSTRIA, REGIÃO E HABILIDADES: UMA NOVA VISÃO

Este capítulo apresenta uma revisão da literatura sobre indústria e o espaço geográfico, com a ênfase nas regiões brasileiras. Além disso, o capítulo apresenta uma nova abordagem: a sofisticação das ocupações envolvidas no processo produtivo. Desta forma, o foco é o capital humano, analisado a partir das habilidades utilizadas pela indústria.

2.1 CARACTERÍSTICAS GERAIS DA INDÚSTRIA NO ESPAÇO

A indústria de transformação é um setor da economia que envolve a produção de bens (tangíveis) manufaturados a partir da transformação de matérias-primas e componentes em produtos acabados. Algumas atividades de serviços também são incluídas na sua definição, tais como os serviços industriais, a montagem de componentes de produtos industriais, a instalação de máquinas e equipamentos e os serviços de manutenção e reparação (Brasil, 2023a). As empresas da indústria de transformação representam 97,9% das empresas industriais (Brasil, 2023b). Dada sua importância no âmbito nacional e do escopo desta tese, a análise restringe-se à indústria de transformação, que se denomina, por convenção, como indústria.

A indústria era responsável por 11.79% do PIB, 57.1% das exportações e 23% do emprego formal brasileiros em 2019, além de ser mais intensiva em inovação em relação aos demais setores da economia (Brasil, 2018; Brasil, 2018a; Brasil, 2018b). Pelo lado do emprego formal (Tabela 1), a indústria cresceu entre 2003 e 2013, passando de 8.14 para 12.89 milhões de trabalhadores. Após 2013 o emprego formal na indústria diminuiu, atingindo 10.94 milhões de trabalhadores em 2019. Apesar desse recorte temporal mostrar a dinâmica do emprego industrial condicionada aos ciclos econômicos, a sua participação em relação ao emprego total formal vem reduzindo-se sistematicamente, evidenciando o processo precoce de desindustrialização (Morceiro, 2018). A participação do emprego formal da indústria no emprego total foi de 27.5% em 2003 e passou para 26.3% e 23.5% em 2013 e 2019, respectivamente (Brasil, 2018a).

A indústria pode ser classificada por sua natureza jurídica como pública ou privada. A indústria pública é caracterizada pelas entidades dotadas de personalidade jurídica de direito privado, com patrimônio próprio e capital inteiramente público, pertencente à União, aos Estados, ao

Distrito Federal ou aos Municípios⁵. Sua criação é autorizada por lei para a exploração de atividade econômica (Brasil, 2023c). A indústria pública desempenha um papel importante para a economia, especialmente em áreas consideradas estratégicas para o desenvolvimento nacional. A indústria privada é constituída por organizações privadas, com capital inteiramente privado ou misto, que operam no setor industrial, excluindo aquelas pertencentes à União, aos Estados, ao Distrito Federal ou aos Municípios.z

Tabela 1: Emprego formal na indústria brasileira em 2003 e 2019

Anos	Total (milhões)	Pública (%)	Privada (%)
2003	8.14	0.64%	99.36%
2004	9.02	0.54%	99.46%
2005	9.34	0.49%	99.51%
2006	10.03	0.41%	99.59%
2007	10.78	0.41%	99.59%
2008	11.14	0.39%	99.61%
2009	11.17	0.33%	99.67%
2010	12.14	0.34%	99.66%
2011	12.52	0.35%	99.65%
2012	12.61	0.21%	99.79%
2013	12.89	0.28%	99.72%
2014	12.67	0.26%	99.74%
2015	11.71	0.27%	99.73%
2016	11.00	0.25%	99.75%
2017	10.95	0.23%	99.77%
2018	10.94	0.24%	99.76%
2019	10.98	0.18%	99.82%

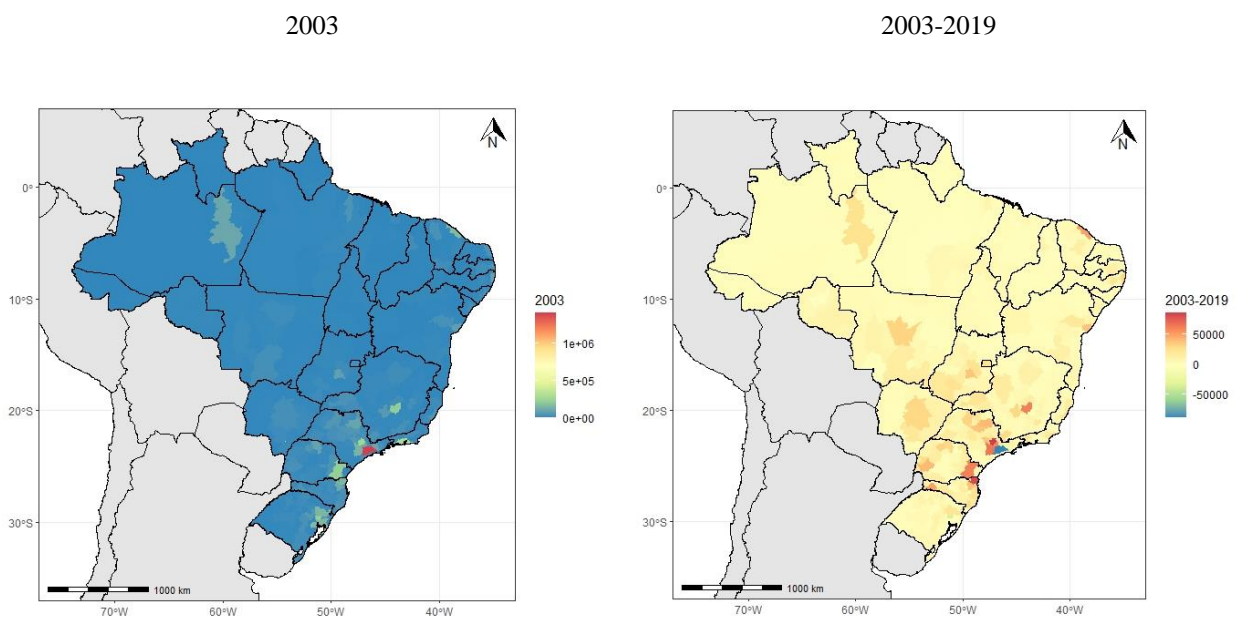
Fonte: Brasil (2023d).

Como apresenta a Tabela 1, a participação do emprego formal na indústria pública é pequena em comparação com a indústria formal privada. Devido à sua baixa participação, esta tese se concentrará na indústria formal privada. Portanto, seguindo a argumentação anterior, denominar-se-á a indústria como a indústria de transformação formal privada. Como o foco desta tese também é o mercado de trabalho formal, os indicadores utilizados na indústria são derivados dos microdados da RAIS. Assim, os indicadores de emprego, estabelecimentos e outros da indústria referem-se ao mercado formal de trabalho.

⁵ Artigo 3º da Lei 13.303/2016.

A Figura 1 apresenta o mapa de calor⁶ da distribuição espacial dos empregos na indústria. A distribuição espacial do emprego na indústria é concentrada nas regiões Sudeste e Sul, além das capitais e da Zona Franca de Manaus (Figura 1)⁷. Em 2003, o emprego formal na indústria privada correspondia a 8.09 milhões de empregos. Os setores que mais empregavam em 2003 eram “Confecção de peças do vestuário, exceto roupas íntimas”, “Instalação de máquinas e equipamentos industriais” e “Fabricação de equipamentos e acessórios para segurança e proteção pessoal” (Apêndice A – Tabela A.1). As ocupações mais comuns eram “Alimentador de linha de produção”, “Auxiliar de escritório” e “Costureiro na confecção em série” (Apêndice A – Tabela A.2).

Figura 1: Distribuição espacial dos empregos na indústria



Fonte: Brasil (2023d).

Em 2019, o emprego da indústria foi de 10.96 milhões de trabalhadores (Tabela 1). Os setores que mais empregavam eram “Fabricação de produtos de carne”, “Instalação de máquinas e equipamentos industriais” e “Abate de suínos, aves e outros pequenos animais” (Apêndice A –

⁶ Um mapa de calor é uma representação gráfica de dados que utiliza cores para indicar a intensidade de uma determinada variável em uma área geográfica. Ele é frequentemente usado para visualizar a distribuição espacial ou a concentração de valores em uma região específica.

⁷ A indústria nasceu de maneira tímida e sua expansão ocorreu somente a partir do final do século XIX e se concentrou na cidade de São Paulo e na região metropolitana. O pico da concentração regional da indústria no Brasil ocorreu em 1970 e o estado de São Paulo detinha 58% da produção nacional (Diniz & Mendes, 2021).

Tabela A.1). As ocupações mais comuns eram “Alimentador de linha de produção”, “Auxiliar de escritório” e “Magarefe” (Apêndice A – Tabela A.2).

Entre 2003 e 2019 o emprego formal na indústria cresceu aproximadamente 35% e sua participação em relação à indústria pública aumentou. Destaque-se o aumento do emprego na indústria nas regiões Centro-Oeste, Oeste dos estados do Paraná, Santa Catarina e Bahia e na região Leste de Santa Catarina. Destacam-se também as RGI⁸ de: Campinas - SP; Sorocaba – SP; Joinville – SC; Curitiba – PR e Jundiaí - SP. Por outro lado, as RGI que tiveram as maiores variações negativas do emprego foram: São Paulo - SP; Novo Hamburgo/São Leopoldo – RS; Rio de Janeiro - RJ; Palmares - PE; e; São Miguel dos Campos - AL.

A Figura 2 mostra o espraiamento da atividade industrial, saindo das regiões tradicionalmente industrializadas para o interior do país. Mesmo com essa variação no número de empregos em direção ao Centro Oeste e Sul, o emprego ainda é concentrado nas regiões tradicionalmente mais importantes em termos industriais no país.

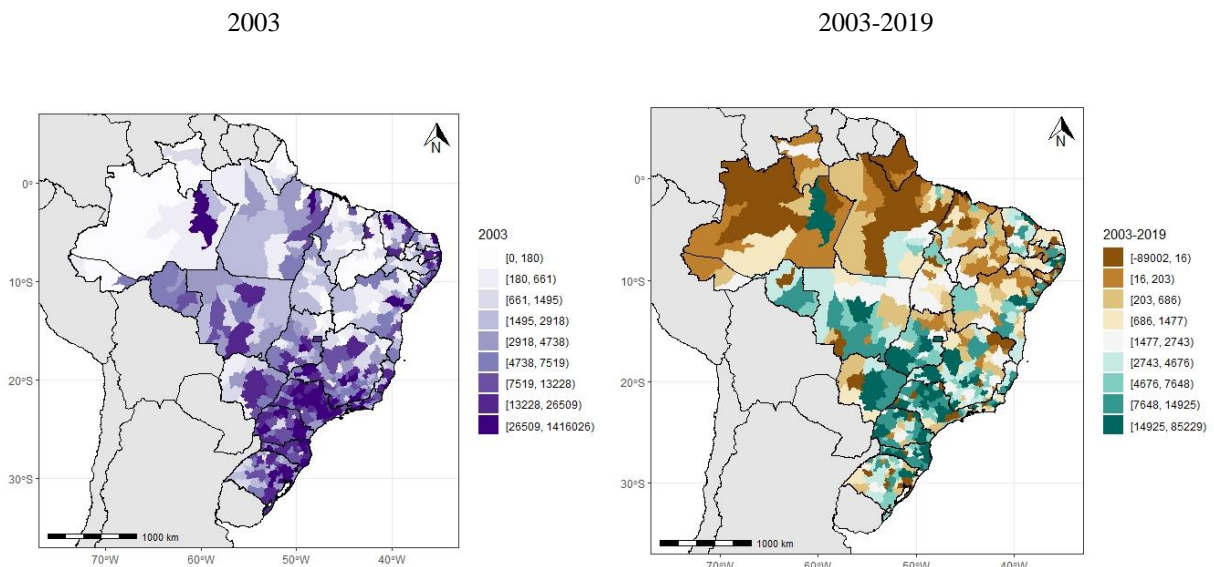
Uma outra maneira de visualizar os dados espaciais da indústria é através de análises por quantis de emprego. A interpretação de mapas por quantis é uma forma de dividir dados geoespaciais em classes com base nos valores dos quantis. Esse tipo de mapa é útil para compreender a distribuição espacial dos dados e identificar padrões geográficos. A análise por quantis em mapas é semelhante à análise por quantis em gráficos, mas, em vez de dividir os dados em partes iguais por número, os dados são divididos em partes iguais por categoria geográfica. A Figura 2 mostra a distribuição espacial do emprego dividido em nove partes iguais (9-quantis), ou seja, cada conjunto representa aproximadamente 11,11% das RGI e contém aproximadamente 57 RGI em cada conjunto.

No mapa de emprego em 2003 podem-se identificar padrões geográficos interessantes. Por exemplo, áreas mais escuras indicam níveis mais elevados de emprego, como nas Regiões Sudeste, Sul e na Zona Franca de Manaus, enquanto áreas mais claras representam níveis mais baixos, como nas Regiões Norte e Nordeste. Isso demonstra uma distribuição não uniforme do emprego entre as 9 classes em 2003, destacando a concentração espacial nas RGI mencionadas anteriormente. É importante observar que as sete primeiras classes abrangem 78,23% das RGI. No entanto, ao comparar o limite inferior da primeira classe (0 empregos) com o limite superior da sétima classe (13.288 empregos), percebe-se o baixo nível de emprego industrial nas RGI e

⁸ RGI – Região Geográfica Imediata, conforme classificação do IBGE (Brasil, 2017).

sua maior concentração nas regiões Norte, Nordeste e Centro-Oeste. Para destacar a disparidade dentro de uma classe e ressaltar a concentração espacial do emprego, registra-se que a diferença entre o limite superior e o limite inferior da classe com o maior número de empregos industriais é de 1.389.517 milhões de empregos (RGI de São Paulo - SP, com 1,4 milhão de empregos; RGI de Campinas – SP, com 26.509 empregos).

Figura 2: Distribuição espacial do emprego na indústria por quantil



Fonte: Brasil (2023d).

A Figura 2 exibe a variação do emprego por decil entre 2003 e 2019, destacando os grupos que mais perderam empregos (áreas em tons de marrom) e os que mais ganharam (áreas em tons de verde). Estes últimos estão localizados no interior dos estados de São Paulo, Santa Catarina, Paraná, Mato Grosso, Mato Grosso do Sul e Goiás. Surpreendentemente, mesmo sendo a RGI com o maior número de empregos, São Paulo - SP perdeu 89 mil empregos durante o período analisado. Enquanto isso, a RGI de Novo Hamburgo-São Leopoldo – RS registrou uma perda de 35 mil empregos no mesmo período. Por outro lado, as RGI de Campinas – SP e Joinville – SC ganharam 85 mil e 81 mil empregos, respectivamente. Na região Centro-Oeste, as RGI de Goiânia – GO e Sorriso – MT foram as que mais ganharam empregos, com 36 mil e 30 mil novas vagas na indústria, respectivamente.

Essas mudanças no emprego em direção à região Sul e Centro Oeste refletem a criação de várias aglomerações industriais nos estados que pertencem a essas regiões. Essas novas aglomerações estão predominantemente ligadas aos setores agroindustriais (açúcar, frigorífico,

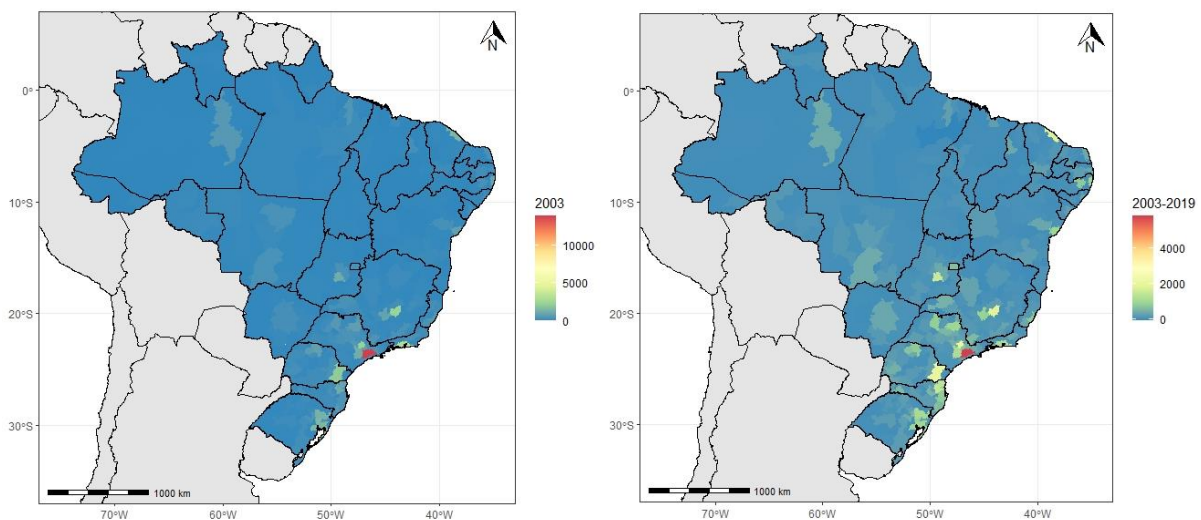
beneficiamento de cereais, alimentos industrializados em geral, insumo agropecuários etc.). No caso de Goiás, foi criada uma aglomeração de emprego industrial ligada à atividade automotriz, insumos agrícolas e equipamentos, como as empresas John Deere (Diniz & Mendes, 2021). Já Joinville - SC se destaca por apresentar empregos na indústria metalúrgica, mecânica, têxtil e plásticos (Hoenicke, 2007).

No período em análise o emprego na indústria cresceu aproximadamente 31% enquanto o número de estabelecimentos praticamente dobrou, indicando uma redução de trabalho formal por estabelecimento. A distribuição espacial do emprego é semelhante à distribuição dos estabelecimentos. A Figura 3 mostra a concentração dos estabelecimentos nas RGI em um mapa de calor para os anos de 2003 e 2019.

Figura 3: Distribuição espacial das indústrias

2003

2003-2019



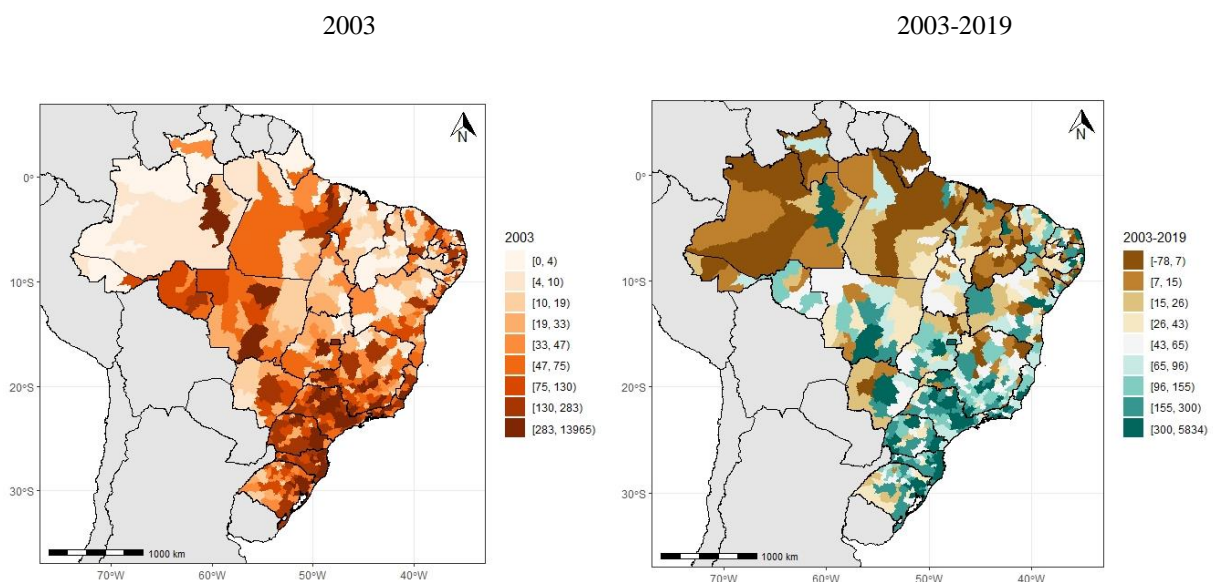
Fonte: Brasil (2023d).

Há concentração dos estabelecimentos em torno do Sudeste e Sul e nas capitais do país. A Figura 3 mostra que em 2003 o número de estabelecimentos da indústria era 78,2 mil, subindo para 156,2 em 2019. Entre esses anos houve uma variação positiva de aproximadamente 78 mil novos estabelecimentos. Entretanto, percebe-se que novos estabelecimentos industriais permaneceram nas regiões tradicionalmente industrializadas e com alguns avanços para as regiões Centro-Oeste, Oeste do Paraná e da Bahia e Leste de Santa Catarina, com destaque positivo para as RGI de: São Paulo - SP; Curitiba - PR; Campinas - SP; Belo Horizonte - MG

e; Fortaleza - CE. As RGI que tiveram as maiores variações negativas foram: Paragominas - PA; Tucuruí - PA; Breves - PA; Altamira - PA e; Açailândia - MA.

A Figura 4 apresenta a distribuição espacial dos estabelecimentos divididos em nove partes iguais (9 quantis), ou seja, cada conjunto representa aproximadamente 11,11% das RGI e contém cerca de 57 RGI em cada conjunto. Para o mapa dos estabelecimentos em 2003, identificam-se padrões geográficos semelhantes aos da Figura 2. Por exemplo, áreas com cores mais escuras em tons de laranja indicam valores mais elevados de estabelecimentos (Regiões Sudeste, Sul, Centro-Oeste e Zona Franca de Manaus), enquanto áreas com cores mais claras representam valores mais baixos (Regiões Norte e Nordeste). Portanto, não há uma distribuição uniforme no espaço entre as 9 classes de estabelecimentos em 2003, destacando a concentração espacial dos estabelecimentos nas RGI mencionadas anteriormente. Importante notar que as oito primeiras classes compreendem 78,82% das RGI. No entanto, ao comparar o limite inferior da primeira classe (0 estabelecimentos) com o limite superior da oitava classe (283 estabelecimentos), fica evidente a escassez de estabelecimentos industriais em muitas RGI, principalmente nas regiões Norte e Nordeste. Para ressaltar a disparidade dentro de uma classe e enfatizar a concentração espacial dos estabelecimentos, a diferença entre o limite superior e o limite inferior da última classe, que compreende o maior número de estabelecimentos, é de 13.682 estabelecimentos (RGI de São Paulo – SP, com 13 mil estabelecimentos; RGI de Chapecó – SC, com 289 estabelecimentos).

Figura 4: Distribuição espacial das indústrias por quantil



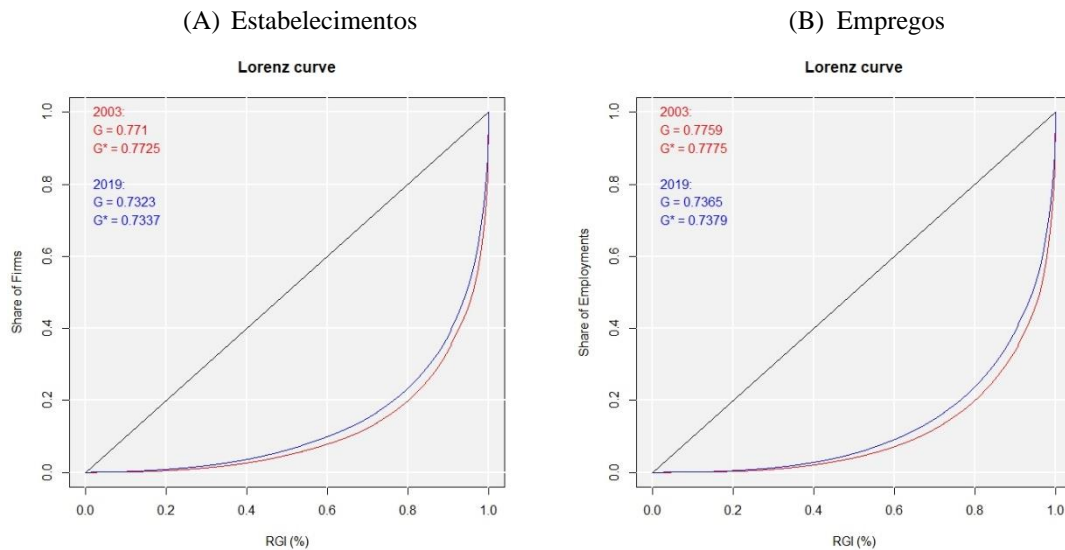
Fonte: Brasil (2023d).

A Figura 4 apresenta a variação de estabelecimentos por quantil entre 2003 e 2019, destacando os grupos que mais perderam (áreas com cores em tons de marrom) e que mais ganharam (áreas com cores em tons de verde) estabelecimentos. Os grupos que mais ganharam estão localizados nos estados de São Paulo, Paraná, Rio de Janeiro e Santa Catarina. Por exemplo, a RGI de São Paulo – SP ganhou 5,8 mil novas indústrias durante o período analisado. Em contrapartida, as RGI do Estado do Pará foram as que mais fecharam empresas, totalizando aproximadamente 185 no mesmo período. No Centro-Oeste, as RGI de Goiânia – GO, Distrito Federal - DF e Cuiabá se destacaram, ganhando 1,5 mil, 665 e 374 novas indústrias, respectivamente.

A variação no número de firmas pode estar relacionada à integração das aglomerações industriais relevantes por adensamento ou corredores industriais. Por exemplo, no Estado do Paraná, além da dimensão industrial no entorno de Curitiba, forma-se um eixo industrial entre Londrina e Maringá, passando por Araongas e Apucarana, com mais de 100 mil empregos industriais. Em Santa Catarina, há grande faixa litorânea ligada pela BR-101 entre Joinville e Florianópolis, incluindo as áreas industriais de Jaraguá do Sul, Itajaí e Blumenau, com mais de 300 mil empregos industriais (Diniz & Mendes, 2021).

Percebe-se também que algumas regiões que tiveram aumento no número de estabelecimentos tiveram redução no número de emprego, como o caso da RGI de São Paulo - SP. Mesmo com essa variação no número de empregos formais em direção ao Sul e ao Centro Oeste, o emprego ainda é concentrado nas regiões tradicionalmente mais importantes em termos industriais no país. A Figura 5 mostra que o índice de Gini para os estabelecimentos reduziu-se de 0.771 em 2003 para 0.732 em 2019. Pelo lado do emprego a redução foi similar, passando de 0.775 em 2003 para 0.736 em 2019. A evolução do índice entre os anos de 2003 a 2019 indica redução da concentração dos estabelecimentos e do emprego. Em 2003, 177 RGI, correspondendo a 34,7%, concentravam 90% dos estabelecimentos; em 2019, esse percentual passou para 40,0%, correspondendo a 204 RGI. Pelo lado do emprego, 33,9% das RGI (173) concentravam 90% do emprego em 2003; já em 2019 esse percentual passou para 38,4%, correspondendo a 196 RGI.

Figura 5: Concentração dos estabelecimentos da indústria (A) e do emprego industrial (B) nas regiões em 2003 e 2019 - Índice de Gini e Curva de Lorenz



Fonte: Brasil (2023d).

De maneira geral, as regiões tradicionalmente industrializadas do Sudeste mantiveram suas posições de relevância, com expansão do emprego e estabelecimentos para a região Sul e com expansão para o Oeste do Brasil, principalmente por meio do Sul dos estados de Goiás e Mato Grosso, e o centro Amazonense (com a Zona Franca Manaus). Na Região Nordeste, as mesorregiões do estado da Bahia são as de maior expressão, com destaque para as regiões que contêm as capitais e as zonas metropolitanas, como também apontado no estudo de Schettini & Azzoni (2018).

É importante destacar que a desconcentração industrial brasileira não é algo recente, uma vez que há evidências empíricas de desconcentração desde a década de 1970. As justificativas para o processo de desconcentração passam pelo aspecto econômico e governamental. Pelo aspecto econômico, as justificativas são: i) deseconomias de aglomeração na RM de São Paulo; ii) expansão e melhoria da infraestrutura em outras regiões; iii) crescimento urbano; iv) expansão da fronteira agrícola, pecuária e mineral para o Centro Oeste e Norte. Pelo aspecto governamental, as justificativas são: i) transferência da capital para Brasília e a integração com os grandes eixos viários; ii) guerras fiscais na atração de investimentos; iii) incentivos fiscais para a Zona Franca de Manaus e para o Nordeste (Diniz & Mendes, 2021). Entretanto, mesmo com a desconcentração observada nas últimas décadas, o adensamento industrial no espaço é representado por meio de um polígono cujos os vértices são Belo Horizonte, Uberlândia,

Londrina, Porto Alegre, Florianópolis e Belo Horizonte, incluindo São Paulo capital e o interior (Diniz, 1993).

Os resultados das análises da distribuição espacial do emprego e dos estabelecimentos da indústria desta tese estão de acordo com o estudo de Saboia (2013). O autor mostra evidências de confirmação do processo de desconcentração espacial da indústria nos anos 2000, beneficiando parte da região Sul do país e identificando um esvaziamento na região metropolitana de São Paulo e outras regiões metropolitanas do Sul/Sudeste. O autor ainda evidencia um deslocamento das atividades industriais em direção ao interior da região Sul/Sudeste e para o interior de regiões menos desenvolvidas do país, como o Centro Oeste. Sobrinho & Azzoni (2016) encontraram evidências de um processo de desconcentração industrial contínuo no período de 2000-2010, porém ainda sem conseguir alterar significativamente o quadro geral de concentração das aglomerações industriais relevantes, mesmo com surgimento de novos polos no Sul e Sudeste. Monteiro Neto, Silva & Severian (2019) identificaram a existência ou criação de várias pequenas aglomerações industriais dispersas no território brasileiro. Ressalte-se que algumas são unidades processadoras de insumos de origem mineral, vegetal ou agropecuário, voltadas para exportação internacional ou inter-regional. Porém, a maioria não gera integração produtiva. Silva & Diniz (2020) constataram que a indústria brasileira enfrenta um processo de desconcentração geográfica pelo índice de aglomeração Ellison-Glaeser de aproximadamente 2,7% ao ano, variando entre setores e macrorregiões. Por exemplo, este processo é mais acelerado nas regiões Norte e Nordeste (regiões com menores níveis absolutos de estabelecimentos indústrias) e menos acelerado nas regiões Sul e Sudeste (regiões com maiores níveis absolutos de estabelecimentos indústrias), acentuando o processo de disparidade regional entre essas regiões. Diniz & Mendes (2021) evidenciam que houve uma expansão do polígono industrial, formando um novo polígono cujos vértices são Belo Horizonte, Anápolis, Rio Verde, Campo Grande, Foz do Iguaçu, Santa Cruz do Sul, Porto Alegre, Florianópolis, Volta Redonda e Belo Horizonte.

Uma possível explicação para este processo, além das já mencionadas, é que a concentração das atividades industriais em algumas regiões pode estar relacionada aos níveis de produtividade dessas regiões. Segundo Schettini & Azzoni (2013), existem evidências de concentração de níveis altos de produtividade nas regiões tradicionalmente mais importantes em termos industriais. Por outro lado, aparecem casos de alta produtividade em regiões não tradicionais, provavelmente resultantes da especialização em um ou poucos setores, ligados via de regra ao setor agropecuário. Destacam-se os casos do setor de Alimentos, no Centro-Oeste

e Extremo Oeste Baiano, e o setor de Madeira, no Pará. Assim, observa-se uma expansão das atividades agrícolas para o oeste do país, com consequências industriais já apontadas em Bustos et al. (2016).

Mendes, Hermeto & Britto (2019) descrevem que, mesmo com a melhoria na distribuição espacial do emprego, há um reforço da concentração do trabalho qualificado (maior grau de instrução) e da indústria de alta intensidade tecnológica em São Paulo e seu entorno. Com a alta dos custos nessa região, houve um descolamento de indústria de menor intensidade tecnológica e produtividade para regiões com custos menores, especialmente o Norte e Nordeste.

Todavia, o quadro geral replica as competitividades relativas tradicionais das regiões. As evidências empíricas para os países (Mameli et al., 2014; Kemeny & Storper, 2015; Caragliu et al., 2016) e para o Brasil (Barufi et al., 2016; De Almeida & de Moraes Rocha, 2018; Araújo, Gonçalves & Almeida, 2019) indicam que a atividade produtiva tende a se aglomerar no espaço por diversos fatores, mas com diferenças significativas entre os tipos de indústrias, ocasionando dependência espacial da produção e, conseqüentemente, do emprego e da renda. O aspecto importante dentro dessa literatura de economias de aglomeração é que parte dos estudos concluem que a aglomeração produtiva potencializa a dinâmica do crescimento regional. Logo, se o tamanho da economia local cresce, isso poderá gerar efeitos sobre o crescimento das firmas e da renda dos trabalhadores (Combes & Gobillon, 2015; Neves, Azzoni & Chagas, 2019). Ou seja, novas firmas se instalam em regiões com grandes números de firmas e essa dinâmica se repete em uma espécie de causalção circular cumulativa.

A partir destas constatações, os estudos empíricos se dedicaram a explicar se um espaço econômico mais diversificado poderia incentivar mais transbordamentos de conhecimento, uma vez que as firmas instaladas nesses espaços poderiam receber ideias novas e melhores de firmas que trabalham em setores muito diferentes – teoria das externalidades jacobianas (JAC) ou diversificação produtiva (Morrissey, 2016). Por outro lado, outra parte dos estudos empíricos buscou explicar se a concentração de uma firma em um determinado espaço econômico promove a transferência de conhecimento entre as firmas e facilita a inovação naquela firma específica dentro do mesmo espaço econômico – teoria das externalidades mashallianas (MAR) – especialização produtiva (Galliano, Magrini & Triboulet, 2015).

Em geral, não há um consenso nos resultados sobre o que é melhor para o crescimento econômico regional. Porém, Caragliu et al. (2016) mostra que tanto Marshall e Jacobs estavam certos, embora de forma diferente em contextos diferentes. Assim, o aspecto espacial e setorial é crucial para os resultados. Ou seja, as evidências mostram que o impacto das externalidades MAR e JAC sobre o crescimento regional depende da densidade de atividade da economia regional. Para áreas menos densas, o efeito das externalidades MAR no crescimento do emprego é maior. O oposto se aplica à medida de diversidade. No caso brasileiro, Araújo, Gonçalves & Almeida (2019) evidenciou que as externalidades MAR estão positivamente associadas ao crescimento local e que as externalidades JAC estão negativamente associadas ao crescimento local.⁹ A possível explicação para essa evidência, segundo os autores, é que as regiões menos desenvolvidas e que também apresentaram estruturas econômicas menos diversificadas foram as que mais cresceram no período 1995-2015 (ano de recorte do estudo). Por fim, os autores destacam que, embora as externalidades atuem em uma dimensão local, também têm uma escala regional. Essas externalidades são determinadas por sua trajetória temporal e os efeitos das economias de aglomeração sobre o crescimento local são sensíveis à escolha da agregação setorial.

Como as externalidades não são excludentes dentro de um determinado espaço econômico, Frenken, Van Oort & Verburg (2007) propôs duas categorias derivadas do conceito de diversificação: a variedade relacionada e a variedade não relacionada. Ambos os conceitos são vinculados à geografia econômica evolucionária, que vincula a disseminação de conhecimento ao desenvolvimento econômico (Frenken & Boschma, 2007; Asheim, Boschman & Cooke, 2011). O conceito de variedade relacionada (não relacionada) sugere que um ambiente mais (menos) favorável aos *spillovers* de conhecimento decorre de uma região conter mais (menos) diversidade de setores que se relacionam economicamente e tecnologicamente entre si (Boschma & Iammarino, 2009; Potter & Watts, 2014). Para o Brasil, o estudo de Da Silva, Gonçalves & Araújo (2020) estimou o efeito das variedades relacionadas e não relacionadas sobre o crescimento do emprego nas microrregiões e encontrou evidências de que o crescimento do emprego está positivamente relacionado com a variedade relacionada e não está relacionado com a variedade não relacionada. Pela ótica das habilidades dos trabalhadores formais, Galetti, Tessarin & Triboulet (2021) investigou se as habilidades relacionadas impactavam na mudança estrutural e encontraram evidências positivas entre as habilidades relacionadas e a entrada de

⁹ Silva & Neto (2007) e Da Silva Catela, Porcille & Gonçalves (2010) encontraram efeito positivo para a diversidade. Já Barufi et al. (2016) encontraram efeito negativo para a diversificação.

novas firmas e sobre crescimento do emprego. Entretanto, ambos os estudos empíricos não consideraram os efeitos das economias de aglomeração sobre as variedades relacionadas e não relacionadas.

Outro ponto inerente ao padrão de aglomeração ou de dispersão das atividades produtivas no espaço, principalmente as manufatureiras, é resultante, de acordo com a Nova Geografia Econômica (NGE), de fatores como o tamanho do mercado, densidade do mercado de trabalho e economias externas puras (externalidades MAR). Mais especificamente, a NGE propõe que, na presença de custos de transporte e retornos crescentes de escala, as interações de mercado atraem firmas em direção a regiões que possuem melhor acesso aos mercados consumidores (*Market Access*), fornecedores (*Supplier Access*) para seus produtos – e trabalhadores – que migram sob uma perspectiva de maiores salários e, conseqüentemente, melhor acesso aos produtos e serviços a custos menores (Redding & Venables, 2004).

No caso brasileiro, Fally, Paillacar & Terra (2010) constatou que o acesso ao mercado consumidor e o acesso aos fornecedores têm impacto positivo e significativo sobre os salários dos trabalhadores e que esses resultados são superiores aos encontrados nas regiões europeias. Entender o porquê as firmas e os trabalhadores escolhem se localizar em lugares com maiores densidades de firmas e trabalhadores é importante para entender a dinâmica das disparidades regionais. As possíveis causas, boa parte delas já citadas, podem estar relacionadas à redução de custo no transporte de ideias, como apontado em Glaeser & Gottlieb (2009) ou até mesmo pelos efeitos *spillovers* derivados de mercados de trabalho mais densos, como descrito por Groot, De Groot & Smit (2014), que geram ganhos salariais maiores para os trabalhadores e aumentam a produtividade das firmas.

O modelo microfundamentado de Duranton & Puga (2004) mostra que esses ganhos salariais nos mercados de trabalho mais densos derivam das questões de *sharing*, *matching* e *learning*. Ou seja, quanto maior a aglomeração: (i) maior será a possibilidade de compartilhamento de infraestrutura, de fornecedores e de um pool de trabalhadores com habilidades similares; (ii) maiores serão as chances de ocorrer um *matching* entre trabalhadores e firmas no mercado de trabalho; (iii) maior é a possibilidade de aprender e desenvolver novas tecnologias e práticas empresariais (Puga, 2010; Combes et al., 2010). No Brasil, Neves et al. (2019) buscou identificar a relação entre aglomeração e salários para diferentes perfis de habilidades (cognitivas, sociais, motoras e médias) e encontrou relação positiva entre salários e o porte dos

centros urbanos para trabalhadores alocados em ocupações com perfil de habilidade classificadas como cognitivas.

Outros fatos estilizados e possíveis mecanismos da aglomeração das atividades produtivas no espaço econômico mostram que um alto nível de capital humano local constitui uma vantagem comparativa para a adoção de tecnologias enviesadas por habilidades. Beaudry, Doms & Lewis (2010) mostrou que as tecnologias e o uso intensivo de habilidades foram adotadas em cidades em que havia abundância de trabalhadores altamente qualificados. Já Glaeser, Resseger & Tobio (2009) observou que a evidência apoia a visão de que as indústrias estão respondendo à distribuição de habilidades da área mais do que a visão de que a distribuição de habilidades está respondendo ao mix da indústria da área.¹⁰

Por outro lado, Berry & Glaeser (2005) encontraram evidências de que a demanda por trabalhadores altamente qualificados tem aumentado em cidades altamente especializadas. Logo, áreas com altos níveis de capital humano atrairão um número desproporcional de trabalhadores qualificados (ver também Glaeser & Gottlieb (2008) e Glaeser, Resseger & Tobio (2009)). Já Duranton & Puga (2005) encontraram evidências de que as grandes cidades tendem a se especializar em funções, não em setores. Em particular, as grandes cidades hospedam desproporcionalmente sedes corporativas que podem contar com uma gama mais ampla de serviços ligados a negócios altamente qualificados. David & Dorn (2013) argumentam que as grandes cidades atraem desproporcionalmente não apenas os trabalhadores mais qualificados, mas também os menos qualificados. Ou seja, grandes cidades exibem “caudas gordas” na distribuição de habilidades (ver também Eeckhout, Pinheiro & Schmidheiny (2014), Lin (2011)). Ioannides et al. (2008) e Blinder & Krueger (2013) argumentam que as TIC (Tecnologia da Informação e Comunicação) têm favorecido a realocação e a dispersão da atividade econômica no espaço, devido à redução de custos de algumas atividades empresariais que antes só era possível desenvolver na própria firma e que agora podem ser realizadas fora da firma, como por exemplo o trabalho “*home-office*”.

Assim, a organização da produção industrial no espaço se dá por meio das falhas de mercados, externalidades positivas (MAR e JAC), custos de transporte, infraestrutura, acesso aos mercados, variedade relacionadas e não relacionadas, tamanho do mercado de trabalho e

¹⁰ Há uma forte persistência nos níveis de capital humano em todas as áreas. Conforme observado por Glaeser, Resseger & Tobio (2009) a partir de dados dos EUA, os níveis de capital humano local em 1850 e 1940 estão fortemente correlacionados com os níveis de capital humano atuais.

escolaridade e habilidade dos trabalhadores. Todos esses fatores podem gerar retornos crescentes de escala e fazer com que a produção industrial se aglomere em determinado espaço econômico. Logo, é preciso considerar esses aspectos para entender como a indústria se relaciona no espaço geográfico e como o setor pode ser um motor desenvolvimento ou de desigualdade econômica.

Por fim, apesar das evidências apresentadas nesta seção sugerirem resultados positivos, incluindo o aumento do emprego, o crescimento no número de estabelecimentos e a desconcentração espacial da indústria para ambas as métricas, é importante ressaltar que esses dados refletem uma diminuição da participação da indústria no emprego em comparação com outros setores. Isso corrobora as evidências de desindustrialização precoce e mudanças no modo de produção. Esses padrões podem ser atribuídos ao aumento da dependência da indústria em relação a bens importados para consumo intermediário e final (Castro et al., 2017), bem como ao progresso tecnológico que economiza mão de obra, especialmente na indústria (Adamczyk, 2021). Portanto, é essencial considerar esses fatores para compreender o cenário em que a indústria brasileira está inserida.

2.2 QUALIFICAÇÃO DA ESTRUTURA PRODUTIVA E COMPETITIVIDADE INDUSTRIAL: UMA NOVA PERSPECTIVA

A produtividade, segundo Krugman (1997), não é tudo, mas no longo prazo, é quase tudo. Assim, a capacidade de uma região melhorar seu padrão de desenvolvimento no longo prazo depende quase exclusivamente das suas habilidades em aumentar a produção por trabalhador. A partir dos estudos de Lucas Jr (1988), Romer (1990) e Mankiw, Romer & Weil (1992), constatou-se que, além do capital físico, havia outra variável tão importante quanto para explicar o aumento da produtividade e, conseqüentemente, o crescimento no longo prazo: o capital humano.

A teoria do capital humano relata que a educação torna os trabalhadores mais produtivos e a remuneração do trabalho maior,¹¹ influenciando o progresso econômico de uma região. As evidências empíricas indicam relação positiva entre produtividade e crescimento econômico e o nível de capital humano existente (Benhabib & Spiegel, 1994; Cuaresma et al., 2014; Pelinescu, 2015). Nesses estudos, o capital humano, dimensionado pelo nível de escolaridade, é uma variável relevante, pois o aumento da produtividade está relacionado não somente à acumulação de capital físico, mas também à acumulação de capital humano, que serviria de suporte para minimizar os rendimentos decrescentes advindos do capital físico e proporcionaria crescimento econômico.

Logo, a explicação para as diferenças de produtividade e de crescimento econômico nas regiões está nas diferenças de capital humano entre elas. Essa análise vale para o setor industrial, foco desta tese. A educação, indicador do nível de qualificação dos trabalhadores, surge como alternativa para a redução das disparidades econômicas (Brando (2017) e Rocha et al. (2020)) e ao fortalecimento da competitividade das economias regionais (Donald, Baruch & Ashleigh (2019) e Popova & Petrov (2020)), influenciando ganhos à população, elevando a produtividade do capital humano e também o nível de produtividade do capital físico. Esse efeito se deve à aplicação de novas técnicas e novas habilidades de gestão, reduzindo os custos de produção, possibilitando retornos crescentes de escala e estimulando cada vez mais a competitividade da indústria e o crescimento de determinado espaço geográfico.

¹¹ Ver Mincer (1958); Schultz (1963); Becker (1964).

Assim, o futuro econômico depende de quão competitiva a região tem sido e, principalmente, como evoluirá no futuro. Como apontado, está associado à qualidade do capital humano envolvido nos processos produtivos regionais. Este é o ponto central desta análise: avaliar a sofisticação da produção industrial regional a partir das habilidades das ocupações envolvidas no processo produtivo.

Desta forma, o foco é a capital humano, mas analisado a partir das habilidades demandas pelos setores, neste caso a indústria. Como descrito por Castro & Azzoni (2022, p.42):

Estudos sobre crescimento econômico regional geralmente destacam a qualificação da população regional, em termos de níveis educacionais. Essa é uma variável relevante para indicar o potencial produtivo. Nesta análise adota-se outro ponto de vista, o da demanda por mão de obra por parte da indústria de transformação. Processos produtivos mais complexos envolvem a contratação de pessoas para ocupações que requerem maiores habilidades dos trabalhadores. Determinada região pode ter um conjunto muito grande de pessoas com alto nível de educação, mas as indústrias ali localizadas demandam trabalhadores pouco qualificados, não aproveitando os recursos existentes. Um aspecto relevante da competitividade futura da região, portanto, baseia-se na complexidade das atividades que sedia, complexidade essa que se manifesta nos requerimentos de habilidades dos seus trabalhadores.

Argumento semelhante é apontado por Dawid et al. (2013), em que os autores evidenciam que a produção é caracterizada por complementaridade entre o estoque de capital e as habilidades específicas dos trabalhadores que utilizam o capital. Assim, as mudanças de produtividade em uma região são influenciadas tanto pelo investimento de empresas locais em bens de capital quanto pela evolução da distribuição de habilidades específicas dos trabalhadores empregados na região. A mesma analogia pode ser feita para a indústria, ou seja, o crescimento da indústria depende da sua produtividade, que depende, dentre outros fatores, das habilidades dos trabalhadores ocupados nas indústrias dessas regiões. A mesma analogia pode ser feita para a inovação industrial. Há evidências empíricas de que a difusão de inovações requer habilidades adequadas da força de trabalho das empresas que adotam a inovação (Bassanini & Scarpetta, 2002; Griffith, Redding & Reenen, 2004).

As evidências indicam desconcentração da indústria no Brasil e reforçam o papel da produtividade via qualificação da mão de obra para o avanço industrial nas regiões. Porém, pouco se explora a respeito das habilidades das ocupações na indústria. Ou seja, a indústria pode estar avançando para outras regiões, as regiões podem estar convergindo em termos do número de emprego e de estabelecimentos. Porém, o nível de habilidades das ocupações na indústria pode não estar seguindo essa dinâmica e podem estar acentuando-se as disparidades

regionais. É possível que o emprego e o número de indústrias possam estar crescendo em algumas regiões, porém com ocupações que requerem baixos níveis de habilidades e, conseqüentemente, de salários. Esse é o ponto que será explorado nesta pesquisa.

O indicador escolhido para esta análise é o grau de sofisticação das ocupações presentes na indústria. A suposição básica é que quanto mais sofisticadas as ocupações dos seus trabalhadores, mais competitivas tendem a ser as firmas. Estendendo a ideia para o nível regional, quanto mais sofisticadas as atividades desenvolvidas pelos trabalhadores ali empregados, maior a competitividade industrial regional. A fonte básica de informações é a RAIS – Relação Anual de Informações Sociais, do Ministério da Economia, que indica a ocupação em que está alocado cada trabalhador empregado, seguindo a codificação da Classificação Brasileira de Ocupações.

O passo seguinte é avaliar a complexidade de cada uma das 2.708 ocupações, o que foi feito com base no estudo de Maciente (2013), que adaptou a pesquisa feita pelo *Department of Labor* dos EUA para a realidade brasileira. Por esses estudos, cada ocupação foi descrita, avaliando-se as habilidades requeridas para seu desempenho e a intensidade em que o são. Como resultado, tem-se para o caso brasileiro a relação de habilidades necessárias para desempenhar as funções e a intensidade com que essas habilidades são requeridas. Passo adicional foi dado na tese de doutorado de Neves (2018), que selecionou um subconjunto das 263 habilidades constantes das pesquisas anteriores e as classificou em três grupos: cognitivas, sociais e motoras (Quadro 1).

Quadro 1: Atributos para as habilidades queridas para as ocupações (CBO)

Cognitivas	Ocupação	Sociais	Ocupação	Motoras	Ocupação
-Analisar dados; -Resolução de problemas complexos; ...	-Físico; -Médico -Cirurgião ...	-Coordenação; -Negociação; ... -Instrução; -Serviços;	-Secretário -Executivo; -Diretor de RH; ... -Costureiro; -Tecerão;	-Força dinâmica; -Manuseio de objetos; ... -Flexibilidade do corpo; -Equilíbrio corporal;	-Preparador de Estruturas; -Mecânico; ... -Matemático; -Ouvidor;

Fonte: adaptado de Neves, Azzoni & Chagas (2021).

As habilidades cognitivas indicam raciocínio lógico, capacidade de aprendizado e domínio oral e verbal da língua; habilidades sociais são voltadas para as relações interpessoais no ambiente de trabalho; habilidades motoras refletem destreza manual e vários tipos de habilidades ligadas à força e à capacidade para desempenhar trabalhos extenuantes. Ressalte-se que o grau de

habilidade de uma ocupação é um indicador relevante da sua complexidade. Evidentemente, a sofisticação está mais claramente relacionada com as habilidades cognitivas e, em menor grau, sociais. Porém, mesmo para atividades motoras, quanto maior a habilidade requerida pela ocupação, maior será a sua sofisticação. Tanto o trabalho do borracheiro como do mecânico de aeronaves, por exemplo, requer habilidades motoras, mas o segundo é muito mais sofisticado do que o primeiro, o que está refletido no indicador gerado para as ocupações.

O indicador final exprime-se em intervalo entre zero (nenhuma habilidade daquele tipo requerida) e um (habilidade extrema), para cada dimensão (Tabela 2). Assim, cada ocupação (isto é, cada trabalhador efetivamente empregado) recebe três valores entre zero e um, sendo um para cada tipo de habilidade. Cabe ressaltar que esse indicador, apesar sintetizar a sofisticação da mão de obra, possui uma limitação por considerar fixos no tempo os atributos e os pesos de cada habilidade para cada ocupação. Desta forma, não captura possíveis mudanças nas habilidades que o progresso tecnológico pode trazer no exercício da ocupação. Por exemplo, a tarefa de analisar dados estava presente em poucas ocupações em 2003 e com o avanço tecnológico da internet, da criação de grandes bancos de dados (*Big Data*) e da ciência de dados (*Data Science*), passou a estar presente em mais ocupações em 2019. Mesmo diante desta limitação, as análises das habilidades mostram uma nova forma de avaliar a sofisticação do trabalho, além da ótica convencional da escolaridade que também é fixa no tempo.

Tabela 2: Notas das habilidades requeridas para as ocupações (CBO)

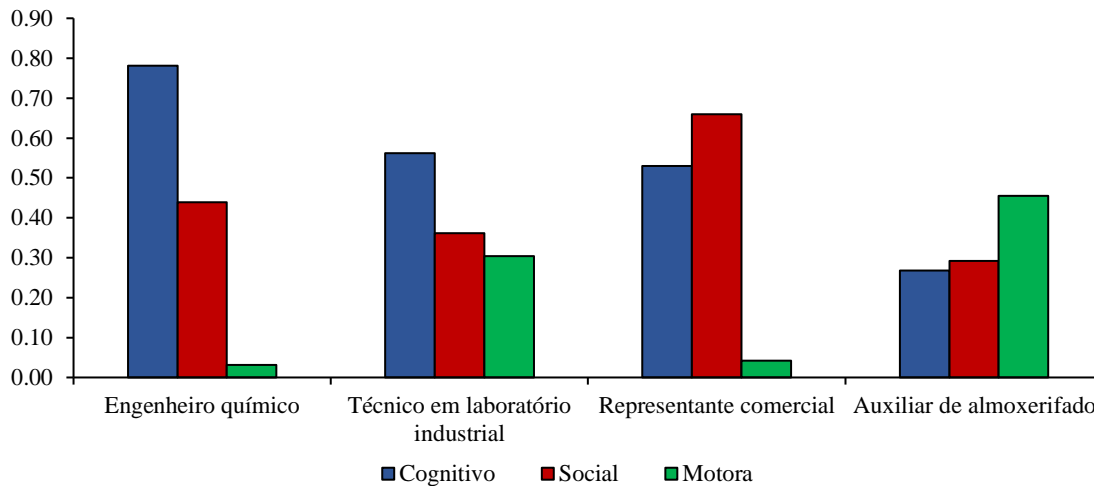
ocupação	Cognitivo	Ocupação	Social	Ocupação	Motora
Físico	1.000	Secretário Executivo	1.000	Preparador de Estruturas	1.000
Médico Cirurgião	0.888	Diretor de RH	0.812	Mecânico	0.681
...
Garçom	0.165	Costureiro	0.125	Matemático	0.003
Atendente	0.145	Tecelão	0.078	Ouvidor	0.000

Fonte: adaptado de Neves, Azzoni & Chagas (2021).

Tomem-se como exemplo as notas de habilidades requeridas em algumas ocupações no segmento de indústria Química (Figura 6). A ocupação de engenheiro químico possui maior nota de habilidade cognitiva, seguida do técnico em laboratório industrial, representante comercial e, por último, auxiliar de almoxarifado. A ocupação de representante comercial possui a maior nota de habilidade social, seguida do engenheiro químico, do técnico em laboratório industrial e do auxiliar de almoxarifado. Por fim, a ocupação de auxiliar de

almoxarifado possui a maior nota de habilidade motora, seguida do técnico em laboratório industrial, representante comercial e, por último, do engenheiro químico.

Figura 6: Habilidades requeridas em algumas ocupações da indústria química



Fonte: elaborado pelo autor (2023).

Usar os indicadores de habilidades em vez de escolaridade pode oferecer diversas vantagens em diferentes contextos de análise. Aqui estão algumas razões pelas quais o uso de um indicador de habilidades pode ser benéfico:

- Reflete a qualificação real: a escolaridade nem sempre reflete com precisão as habilidades reais de um indivíduo. Alguém com muitos anos de educação formal pode não ter as habilidades práticas necessárias para realizar determinadas tarefas, enquanto outra pessoa com menos educação formal pode ter adquirido habilidades valiosas por meio de experiências de trabalho ou treinamento técnico (Di Pietro & Urwin, 2006; Massing & Schneider, 2017).
- Mais precisão na previsão de desempenho: em muitos contextos, como contratação ou avaliação de desempenho, os indicadores de habilidades podem ser melhores preditores do sucesso do que a escolaridade. Isso ocorre porque eles refletem diretamente a capacidade do indivíduo de realizar as tarefas necessárias (Unger et al., 2011; Motowidlo, Borman & Schmit, 2017).
- Avaliação de habilidades específicas: dependendo da área de estudo, pode ser fundamental avaliar habilidades específicas em vez de apenas a educação geral. Por

exemplo, em trabalhos técnicos, as habilidades práticas específicas podem ser mais importantes do que o nível de escolaridade (Cadman & Brewer, 2001).

- Maior flexibilidade: os indicadores de habilidades podem ser mais flexíveis e adaptáveis a diferentes situações. Em um mundo em constante mudança, onde novas tecnologias e habilidades são necessárias, a capacidade de avaliar e atualizar rapidamente as habilidades dos indivíduos é importante (LePine, Colquitt & Erez, 2006).
- Redução de viés educacional: a ênfase na escolaridade pode introduzir viés educacional nas decisões, enquanto os indicadores de habilidades podem fornecer uma avaliação mais equitativa e justa das capacidades individuais (Hanushek & Woessmann, 2011; Ng & Feldman, 2010).
- Comparação internacional: em estudos comparativos entre países, o uso de indicadores de habilidades pode ser mais útil, já que as estruturas educacionais e os currículos variam significativamente (Hanushek & Woessmann, 2011).

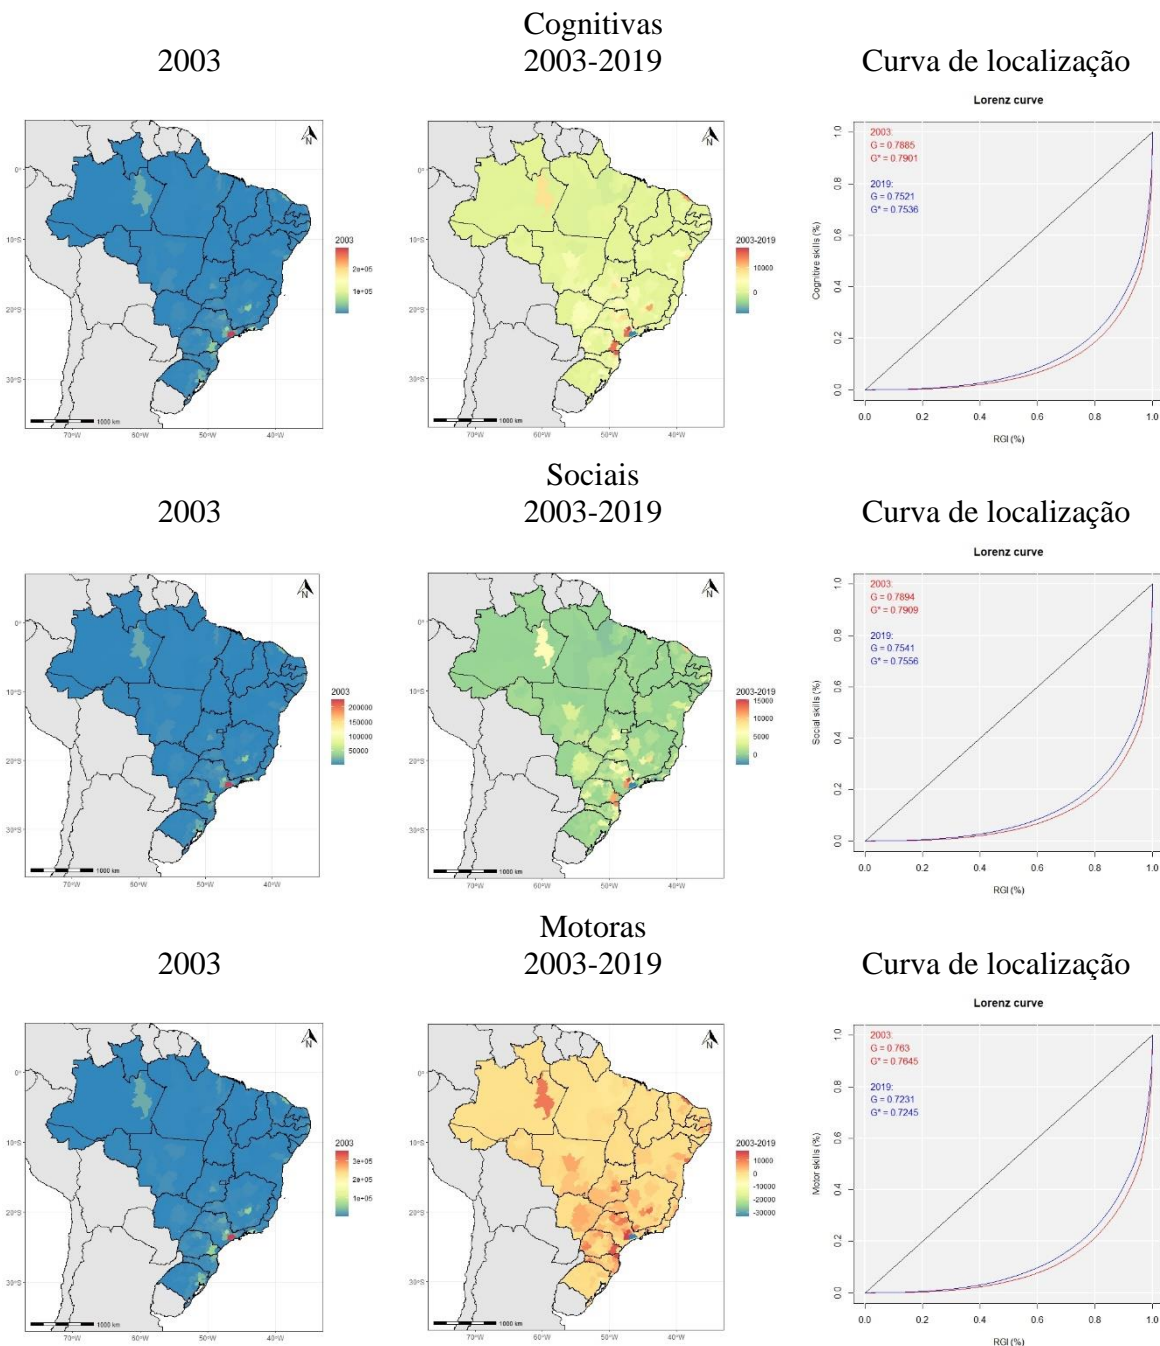
No entanto, é importante notar que a escolaridade ainda é um indicador importante e pode estar correlacionada positivamente com a aquisição de habilidades. Uma abordagem equilibrada, que leve em consideração tanto a escolaridade quanto os indicadores de habilidades específicas pode fornecer uma imagem mais completa da capacidade do indivíduo. A escolha entre um indicador de habilidades e a escolaridade depende das necessidades específicas do contexto.

Indicadores de habilidades de cada trabalhador da indústria são utilizados nesta análise. Em cada região, somam-se os indicadores de habilidades de todos os seus trabalhadores ocupados, gerando um indicador de massa de habilidades e da habilidade média da região. Também se calculam indicadores da média, mediana e as médias dos quartis das habilidades utilizadas nas regiões.

A análise comparativa regional dos níveis e da evolução desses indicadores compõe um quadro comparativo da sofisticação das atividades industriais desenvolvidas e como essa sofisticação varia no tempo, sempre em termos comparativos. Regiões com níveis maiores de sofisticação posicionam-se, por suposição, em melhor situação competitiva. Regiões com evolução positiva (negativa) da sofisticação das ocupações aumentam (diminuem) essa competitividade em comparação com as demais regiões. Foram gerados indicadores anuais, para os anos de 2003 e 2019, permitindo-se compor um quadro comparativo de grande interesse.

A Figura 7 retrata a massa de habilidades da indústria por RGI em 2003 e a sua variação entre 2003 e 2019 em um mapa de calor. O quadro geral da massa de habilidades replica a concentração da atividade industrial (emprego e firmas) nas regiões do Sudeste, Sul e na Zona Franca de Manaus.

Figura 7: Massa e curva de localização das habilidades da indústria nas RGI em 2003 e 2019



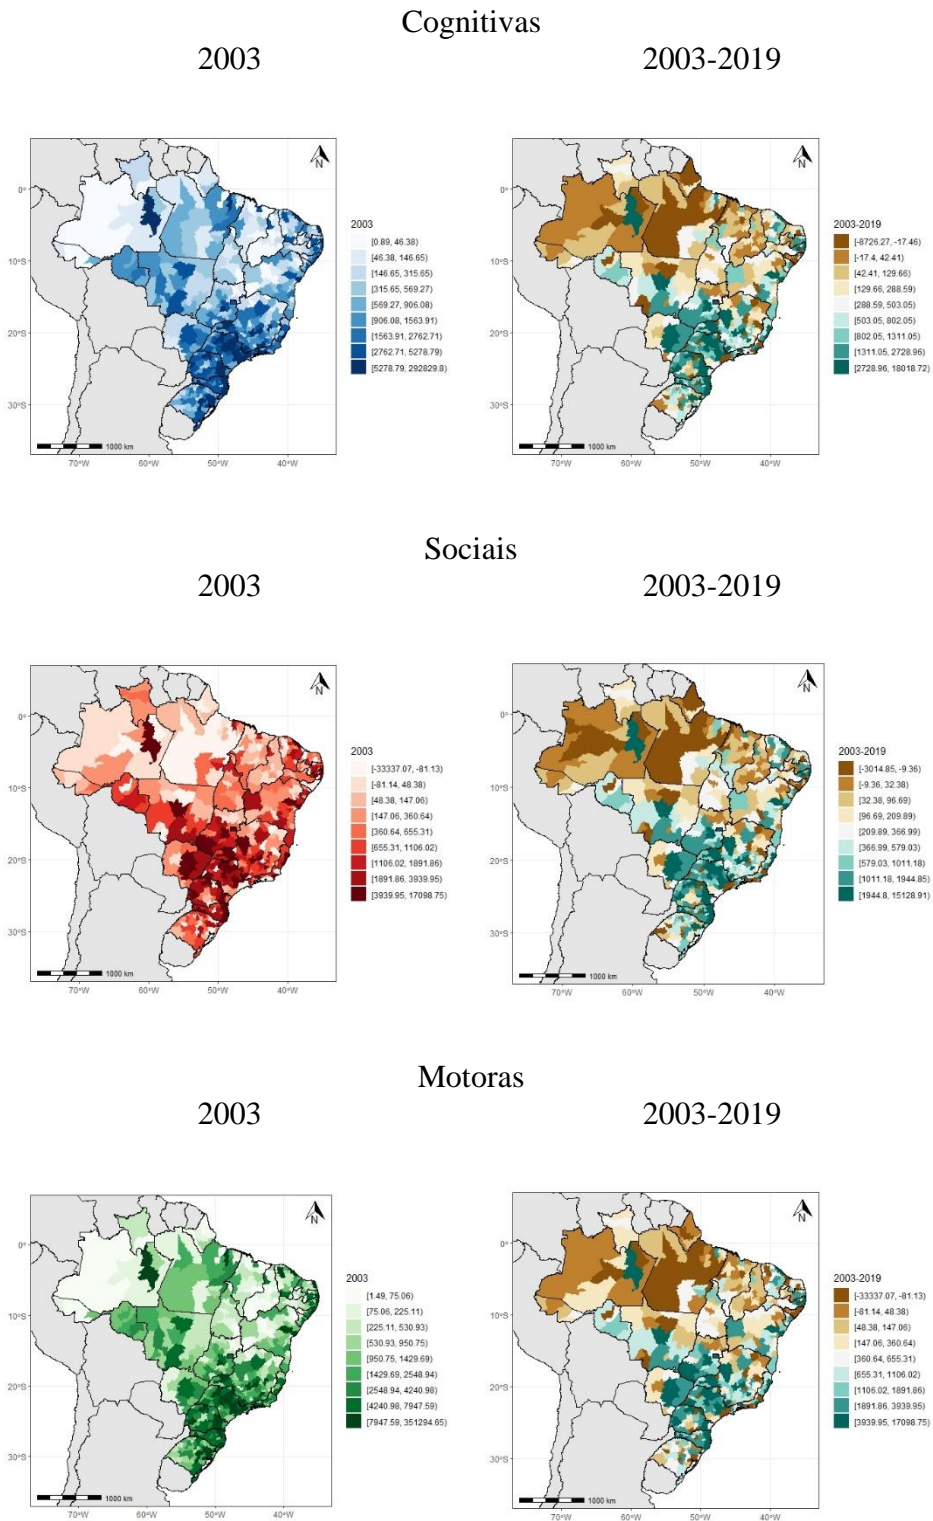
Fonte: elaborado pelo autor (2023).

Em 2003, as RGI que possuíam as maiores massas de habilidades cognitivas, sociais e motoras foram: São Paulo – SP, Rio de Janeiro – RJ e Tatuí – SP. Já as menores para todas as habilidades foram Laranjal do Jari – AP; Tutóia-Araioses – MA e São Gabriel da Cachoeira – AM. Entre 2003 e 2019, a maior parte das RGI teve aumentadas suas massas de habilidades e apenas 12,3% das RGI perderam habilidades cognitivas, 12,1% perderam habilidades sociais e 14,3% perderam habilidades motoras, ressaltando a desconcentração das habilidades da indústria, conforme apresentam as curvas de Lorenz da Figura 7. O índice de Gini da massa de habilidades reduziu-se de 0.78 para 0.75 para as habilidades cognitivas e sociais entre 2003 e 2019. Para as habilidades motoras a redução foi maior, passando de 0.76 em 2003 para 0.72 em 2019. Essas evidências ressaltam que não apenas os estabelecimentos e os empregos estão em processo de desconcentração industrial, mas as habilidades também.

As RGI de Tatuí – SP, Joinville – SC e Sorocaba – SP obtiveram as maiores variações positivas nas habilidades cognitivas e sociais. As RGI de Sorocaba – SP, Joinville – SC e Campinas – SP obtiveram as maiores variações positivas nas habilidades motoras. Por outro lado, as RGI que obtiveram as maiores variações negativas na massa de habilidades cognitivas foram: São Miguel dos Campos – AL; Novo Hamburgo-São Leopoldo – RS e São Paulo – SP. Nas habilidades sociais foram: São Miguel dos Campos – AL; Rio de Janeiro - RJ e São Paulo – SP. Nas habilidades motoras foram: Rio de Janeiro – RJ, Novo Hamburgo-São Leopoldo – RS e São Paulo – SP. Essas regiões também foram as que mais perderam emprego no período analisado.

A mesma análise é apresentada para o quantil da massa de habilidades na Figura 8. Em geral, há em 2003 uma concentração da massa de todas habilidades nas regiões tradicionalmente industrializadas (Sudeste, Sul e Zona Franca de Manaus – AM). Entretanto, há uma variação positiva para regiões do interior do Estado de São Paulo, Paraná e Santa Catarina, bem como para algumas RGI do Centro Oeste e para o litoral do Nordeste entre 2003 e 2019. Embora haja essa desconcentração em direção a regiões que não são tradicionalmente industrializadas, a massa de habilidades ainda é altamente concentrada nas RGI de São Paulo – SP, Rio de Janeiro, - RJ, Novo Hamburgo-São Leopoldo – RS e Campinas – SP. De maneira geral, as massas de habilidades e suas variações replicam a localização do polígono industrial do emprego descrito por Diniz & Mendes (2021).

Figura 8: Massa de habilidades nas RGI em 2003 e 2019

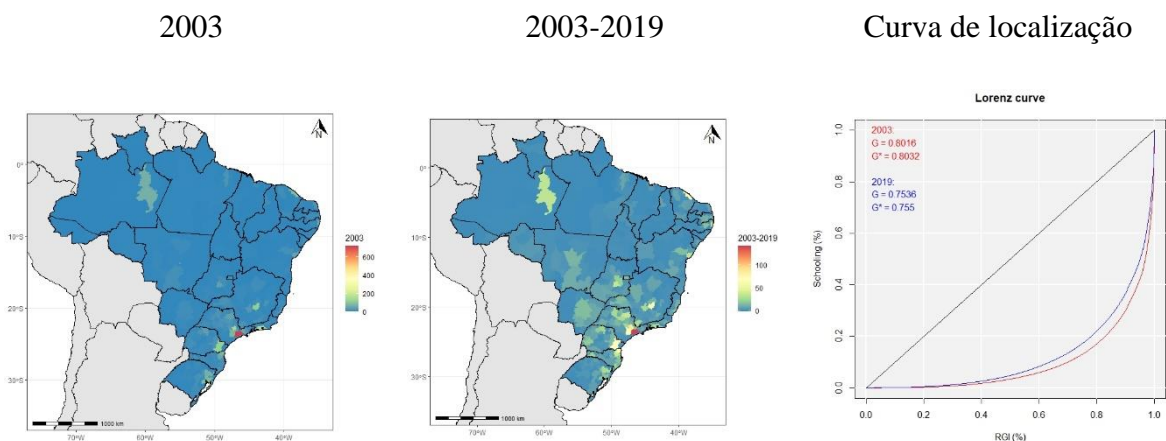


Fonte: elaborado pelo autor (2023).

Nesta tese, argumenta-se que quanto mais sofisticadas forem as ocupações dos trabalhadores em uma determinada região, maior será a competitividade das empresas nela localizadas. Essa sofisticação pode ou não estar diretamente relacionada ao nível de escolaridade dos trabalhadores formais ocupados, uma vez que a escolaridade representa o estoque de capital humano dos trabalhadores presentes nessas regiões. No entanto, as indústrias presentes nessas regiões podem requerer trabalhadores com habilidades sofisticadas, independentemente do nível de escolaridade. Isso pode ter um impacto significativo nas análises de convergência regional.

Portanto, uma questão importante surge: a distribuição espacial das habilidades dos trabalhadores na indústria é semelhante à distribuição espacial do nível de escolaridade desses trabalhadores? Em outras palavras, os trabalhadores de uma região podem estar aumentando seu nível de escolaridade, por exemplo, indo do ensino médio para o ensino superior, enquanto as ocupações das indústrias locais permanecem inalteradas, exigindo as mesmas habilidades cognitivas, sociais e motoras. Nesse sentido, a escolaridade pode ou não restringir as contratações em ocupações que requerem habilidades mais avançadas. Para fazer essa comparação, a Figura 9 apresenta a distribuição espacial da escolaridade da mão de obra empregada na indústria em um mapa de calor por RGI em 2003 e sua variação entre 2003 e 2019.

Figura 9: Massa e curva de localização da escolaridade dos trabalhadores nas RGI em 2003 e 2019



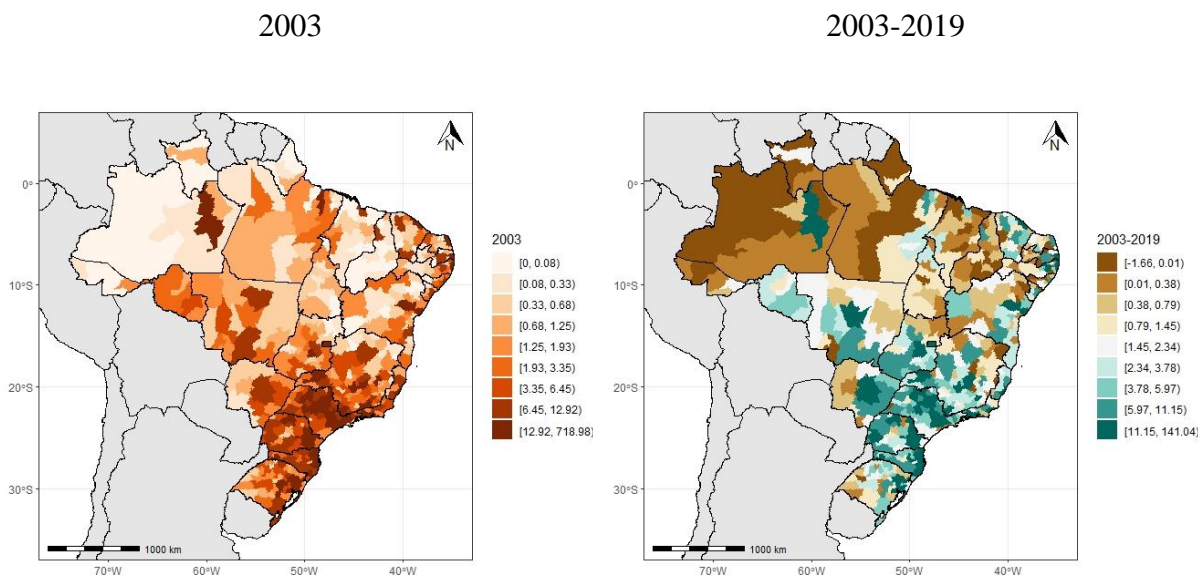
Fonte: elaborado pelo autor (2023).

Assim como para a massa de habilidades, o quadro geral da massa de escolaridade replica a concentração da atividade industrial (emprego e firmas) nas regiões do Sudeste, Sul e na Zona

Franca de Manaus. Em 2003, as RGI que possuíam as maiores massas foram: São Paulo – SP, Rio de Janeiro – RJ, Campinas – SP, Curitiba – PR e Belo Horizonte - MG. Entre 2003 e 2019, a maior parte das RGI teve aumentadas suas massas de escolaridade e apenas 4,31% das RGI perdem escolaridade, ressaltando a desconcentração da escolaridade da indústria conforme a curva de Lorenz apresentada na Figura 9. As RGI que possuíam os maiores valores em 2003 também foram as que mais aumentaram suas massas entre os anos analisados, com destaque para a inserção da RGI de Sorocaba - SP no lugar da RGI do Rio de Janeiro – RJ. O índice de Gini da massa de escolaridade reduziu-se de 0.80 para 0.75 entre 2003 e 2019. Essas evidências ressaltam que a escolaridade dos empregados da indústria também está em processo de desconcentração espacial. Além disso, a redução do índice de Gini entre os anos foi maior para a escolaridade do que para as habilidades.

A mesma análise é apresentada para os quantis da massa de escolaridade na Figura 10. Em geral, há em 2003 uma concentração da massa de escolaridade nas regiões tradicionalmente industrializadas (Sudeste, Sul e Zona Franca de Manaus – AM).

Figura 10: Massa de escolaridade da indústria nas RGI em 2003 e 2019



Fonte: elaborado pelo autor (2023).

Entretanto, há uma variação positiva para regiões do interior do Estado de São Paulo, Paraná e Santa Catarina, bem como para algumas RGI do Centro Oeste, Sul de Minas Gerais e para o litoral do Nordeste entre 2003 e 2019. Embora haja essa desconcentração em direção a regiões

que não são tradicionalmente industrializadas, a massa de escolaridade ainda é altamente concentrada nas RGI de São Paulo – SP, Campinas – SP, Rio de Janeiro, - RJ, Curitiba - PR e Belo Horizonte. De maneira geral, a massa de escolaridade e sua variação também replicam a localização do polígono industrial do emprego descrito por Diniz & Mendes (2021).

Nas últimas décadas, o Brasil testemunhou um período de expansão na educação, especialmente no ensino superior. De acordo com Binelli & Menezes-Filho (2019), a partir da década de 1990 começou uma expansão no ensino superior, tanto na esfera pública (por meio da criação e expansão de universidades estaduais e federais) quanto na esfera privada (com a implementação de programas de financiamento estudantil). Conforme relatado por Carnoy et al. (2014), o número de matrículas no ensino superior em geral aumentou significativamente, passando de 1,8 milhão de alunos em 1995 para 5,4 milhões em 2010. Além disso, dados da Pesquisa Nacional por Amostra de Domicílios (PNAD Contínua) mostram que, de 2016 a 2022, o número médio de anos de estudo das pessoas com 25 anos ou mais de idade aumentou tanto no Brasil como nas Grandes Regiões (Brasil, 2023e).

Esses avanços na oferta educacional permitiram o aumento da participação de trabalhadores com formação superior na agricultura (Cardozo & Cunha, 2019), na indústria de transformação (Mendes, Hermeto & Britto, 2019) e de serviços (Azambuja & Mocelin, 2016). No caso da indústria, tema desta tese, houve redução no número de trabalhadores que possuíam o ensino fundamental e aumento no número de trabalhadores com ensino superior. O número de trabalhadores na indústria com ensino superior, mestrado e/ou doutorado aumentou entre 2008 e 2014 em 70,64%, 125,36% e 55,99%, respectivamente (Mendes, Hermeto & Britto, 2019).

Evidências semelhantes foram apresentadas por Pauli, Nakabashi & Vaz Sampaio (2013), em que os autores argumentam que o aumento da oferta de trabalhadores com qualificação intermediária foi a principal causa do aumento da escolaridade da força de trabalho da indústria no Brasil entre 1994 e 2008. A escolaridade disponível nas regiões é uma das características observadas que influenciam o nível de educação das pessoas empregadas. Desta forma, mesmo que os resultados apresentem aumento e desconcentração espacial da escolaridade dos trabalhadores, a escolaridade ainda é um fator de heterogeneidade nas regiões. Da Silva Filho (2016) apresenta evidências de que a produção industrial é caracterizada por baixa escolaridade na região Nordeste, região que não é tradicionalmente industrializada.

Entre 2008 e 2014 as regiões Centro Oeste e Sul foram as únicas que aumentaram o número de trabalhadores sem grau de instrução e as regiões Centro Oeste e Norte foram as únicas que aumentaram o número de trabalhadores com ensino fundamental. Para os demais graus de instrução houve aumento em todas as regiões no período. Além do mais, há forte correlação entre intensidade tecnológica setorial e grau de instrução do trabalhador, reforçando a posição de destaque da região Sudeste, principalmente do estado de São Paulo, na geração de emprego altamente qualificado (mestres e doutores), em indústrias com alta intensidade tecnológica (Mendes, Hermeto & Britto, 2019). A RM de São Paulo continua concentrando a indústria tecnologicamente mais sofisticada e com maior capacidade de integração e diversificação (Diniz & Mendes, 2021).

Portanto, as evidências apresentadas até aqui indicam que a desconcentração macroespacial da indústria foi tendenciosa em direção ao emprego com grau de instrução inferior, resultando em maior distribuição territorial de setores com menor intensidade tecnológica e empregos que requerem níveis educacionais mais baixos. As habilidades das ocupações da indústria parecem estar seguindo a mesma tendência, embora seja necessária uma análise mais aprofundada neste caso. Em contraste, as regiões tradicionalmente industrializadas continuam mantendo vantagens, com uma indústria mais tecnológica e com trabalhadores mais escolarizados.

Para avaliar a tendência de concentração do ponto de vista geográfico, foi calculado o centro econômico de gravidade usando as 510 RGI (Azzoni & Castro, 2023). Essa medida é simplesmente a média das latitudes e longitudes, ponderadas pelas participações de cada unidade geográfica na massa de habilidades da indústria nacional de cada ano. Chamando a participação da região r sobre a massa de habilidades ou massa de escolaridade nacional no ano t por $s_{r,t}$, tem-se:

$$Lat_t = \sum_r s_{r,t} * Lat_r \quad (1)$$

$$Long_t = \sum_r s_{r,t} * Long_r \quad (2)$$

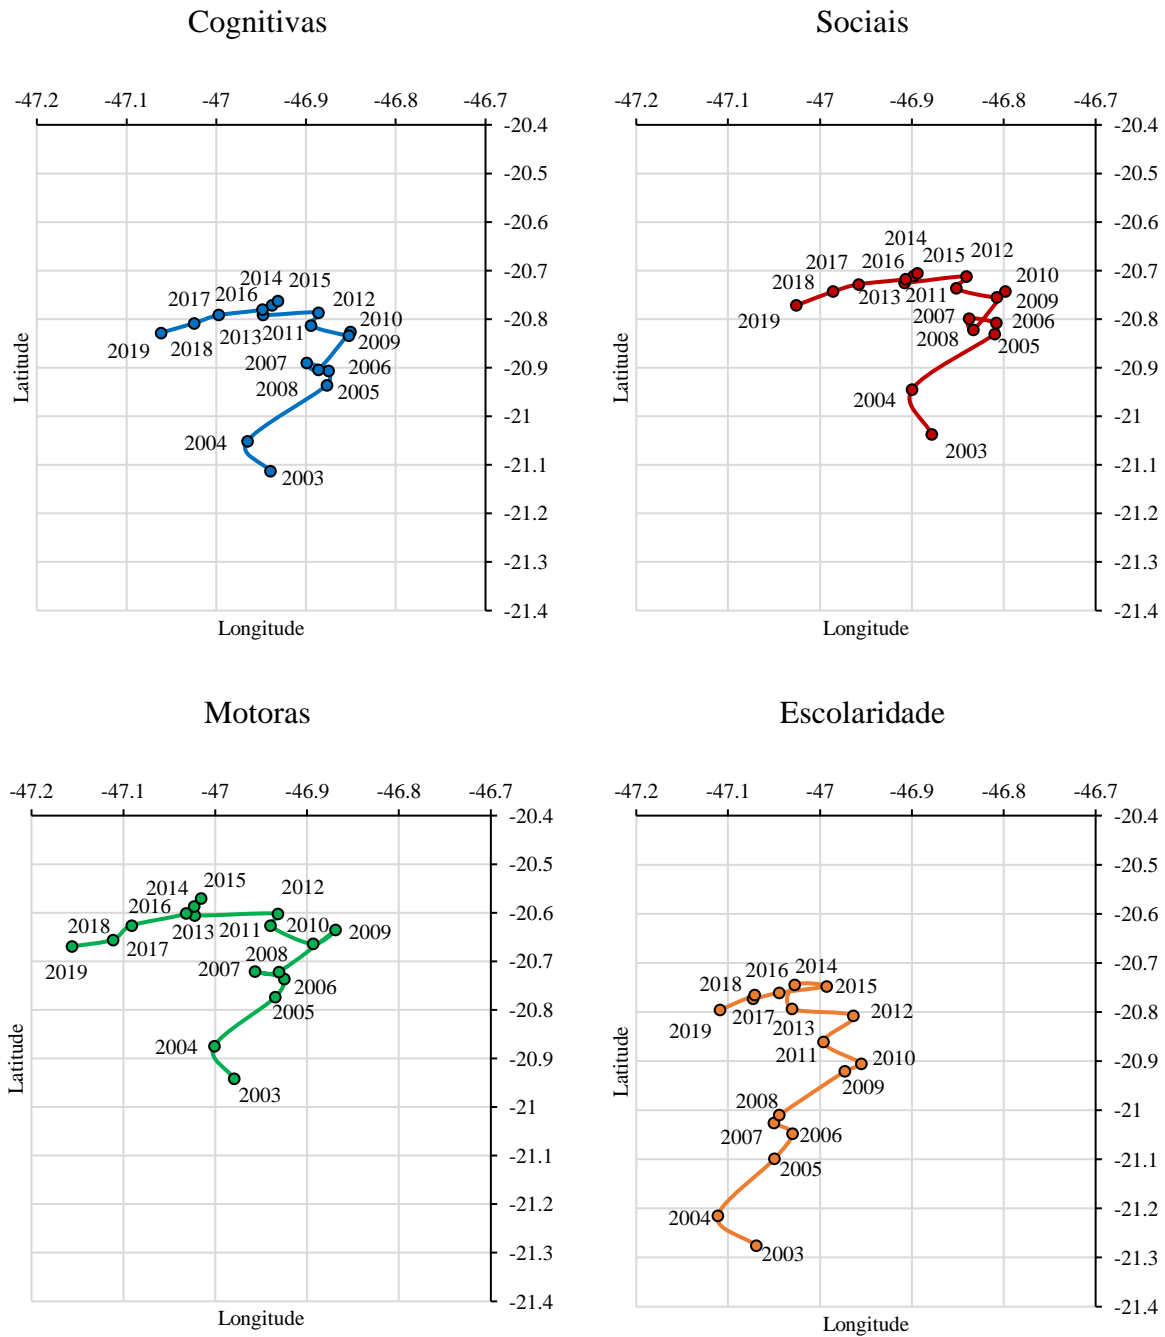
Como Lat_r e $Long_r$ são constantes no tempo, mudanças na latitude e longitude médias são produzidas exclusivamente pelas mudanças em $s_{r,t}$. Portanto, as mudanças em Lat_t refletem as mudanças combinadas nas participações das regiões na soma nacional das habilidades ou

escolaridade ao longo do tempo. A latitude e a longitude médias para um ano específico carecem de qualquer significado econômico. No entanto, sua mudança ao longo do tempo sintetiza o movimento conjunto das economias regionais. Como o movimento do ponto é resultante do crescimento de todas regiões simultaneamente, qualquer movimento ao norte do ponto original, por exemplo, indica que o conjunto de unidades geográficas localizadas ao norte daquele ponto cresceu mais rápido que as unidades localizadas em outros pontos do território.

A Figura 11 fornece uma visão de longo prazo do movimento do centro de gravidade da sofisticação do emprego industrial. A movimentação do centro de gravidade reflete a dinâmica espacial das habilidades e das escolaridades dos trabalhadores da indústria que compõem a produção nacional. A posição inicial dos pontos se dá na região Sudeste, no estado de São Paulo, na RGI de Ribeirão Preto¹². É evidente que o movimento observado neste período é geograficamente limitado. Entretanto, observa-se uma clara orientação para o Centro-Oeste quando se compara o ponto inicial (2003) e o ponto final (2019). De 2003 a 2010 a concentração direcionou-se para o Nordeste. A partir desse ponto, moveu-se claramente para o Oeste, com uma ligeira mudança para o Norte e Leste em 2014 e 2015, respectivamente. O direcionamento para a região Centro-Oeste é maior para as habilidades motoras em comparação com as demais habilidades e com a escolaridade. O movimento do centro de gravidade da massa de habilidades na indústria em direção ao nordeste entre 2004 a 2009 é semelhante ao movimento do centro de gravidade do Valor Adicionado das RGI entre 2003 a 2006 apresentado por Azzoni & Castro (2023).

A dinâmica do centro de gravidade para a escolaridade na indústria reflete, em seu ponto inicial (2003), uma concentração ao Sul superior àquela das habilidades. Entretanto, entre 2003 e 2012, o movimento do centro de gravidade foi mais expressivo no Nordeste em comparação ao Centro-Oeste, entre 2013 e 2019.

¹² O centro de gravidade nessa região é consequência da concentração industrial já mencionada nas seções anteriores.

Figura 11: Centro de gravidade econômico – habilidades e escolaridade, 510 regiões

Fonte: elaborado pelo autor (2023).

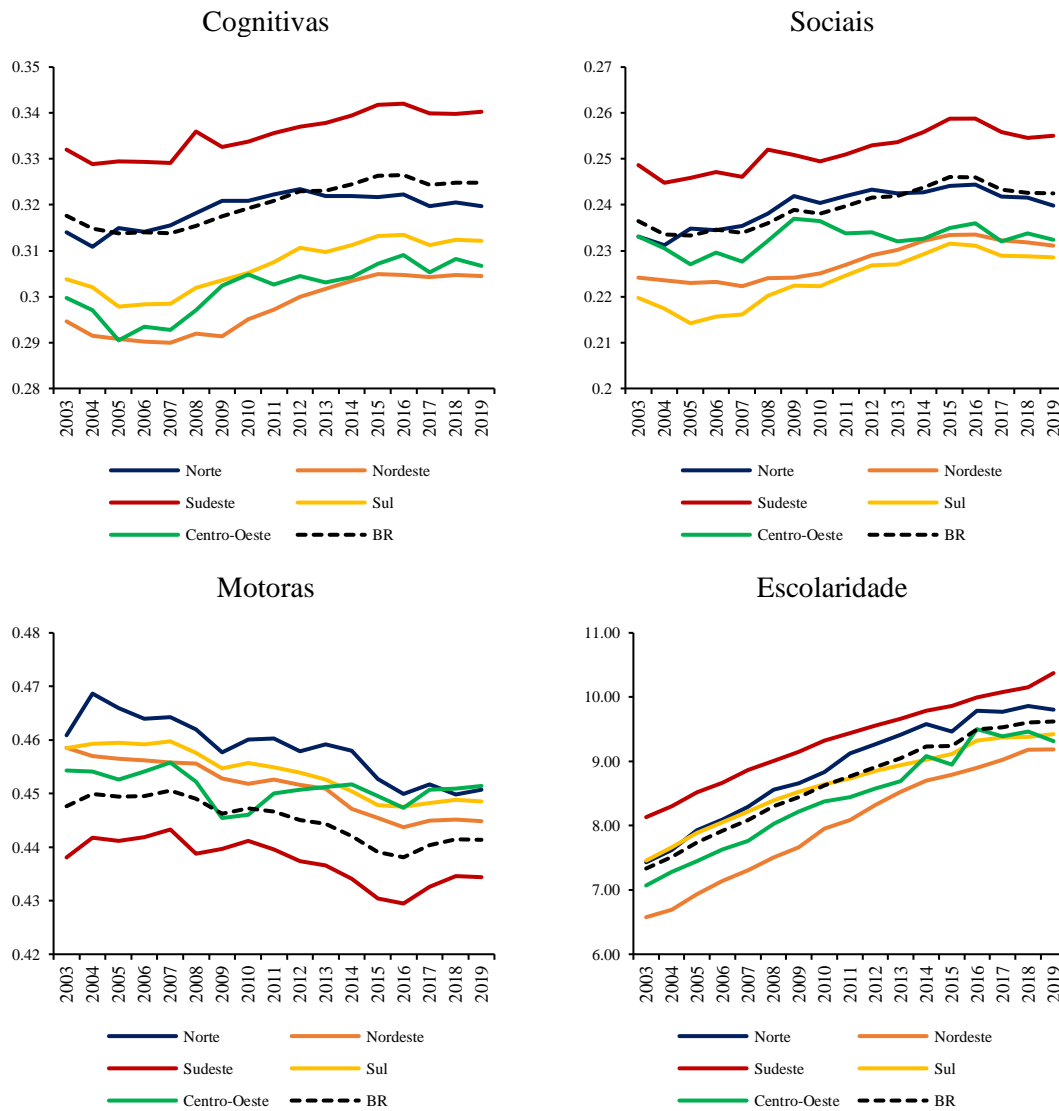
Em geral, apesar da desconcentração macroespacial da indústria em direção às regiões menos industrializadas, observa-se que a tendência do centro de gravidade econômico das habilidades e da escolaridade deslocou-se para o Sul do país, refletindo o peso relativo das regiões tradicionalmente industrializadas sobre as demais.

Para fins comparativos, a Figura 12 mostra os níveis médios de habilidades e escolaridades da indústria no Brasil e para as Grandes Regiões no mesmo período. Em termos gerais, a indústria destaca-se por altos níveis de habilidades motoras empregadas nos seus estabelecimentos, seguida das habilidades cognitivas e sociais. Em 2003, a média das habilidades motoras na indústria foi de 0.447. Já em 2019 houve uma pequena diminuição nas médias de habilidades motoras, passando para 0.441. Para as habilidades cognitivas, os valores médios foram de 0.317 e 0.324 para os anos de 2003 e 2019, respectivamente.

O valor médio das habilidades sociais foi de 0.236 em 2003 e passou para 0.242 em 2019. As Grandes Regiões (GR) seguem as tendências nacionais, o que muda é a composição de cada GR. Desta forma, as GR com maiores notas para as habilidades cognitivas na indústria são: Sudeste, Norte, Sul, Centro Oeste e Nordeste. Para as habilidades sociais são: Sudeste, Norte, Centro Oeste, Nordeste e Sul. Já para as habilidades motoras a ordem é inversa: Centro Oeste, Norte, Sul, Nordeste e Sudeste. Cabe destacar que há uma tendência de queda nas notas de habilidades motoras, exceto para o Centro Oeste, em que as médias são mais estáveis nesse período.

É visível na análise gráfica que há aumentos/diminuições abruptas nas médias em alguns anos para cada nível de habilidade para cada GR. Essas interrupções estão ligadas às crises externas (Subprime em 2008) e internas (iniciadas em 2014). Entretanto, Azzoni & Castro (2023) encontram evidências de que as crises não apresentaram efeito significativo na convergência de habilidades. Portanto, o processo de equalização da competitividade regional, representado pela equalização das habilidades, parece seguir seu caminho independentemente dos choques intensos recebidos pela economia nacional.

Figura 12: Níveis médios de habilidades e escolaridade da indústria nas Grandes Regiões e no BR entre 2003 a 2019



Fonte: elaborado pelo autor (2023).

Em relação à escolaridade, a indústria se destaca pelo contínuo aumento da escolaridade média. Em 2003, a escolaridade média na indústria foi de 7,33 anos de estudo. Já em 2019, esse número aumentou para 9,62. Em ordem decrescente, as regiões com as maiores médias de escolaridade em 2003 foram: Sudeste, Norte, Sul, Centro-Oeste e Nordeste. Essa ordem não se alterou ao longo do período. As regiões Sudeste e Norte apresentaram níveis de escolaridade acima da média nacional em 2019, enquanto as regiões Centro-Oeste e Nordeste ficaram abaixo dessa média a partir de 2010.

Em geral, a indústria está com menos ocupações em habilidades motoras e mais ocupações com habilidades cognitivas e sociais. Além disso, a indústria está utilizando trabalhadores mais

escolarizados em média. Como destacado na seção 2.1, embora as evidências sugiram que esses dados são positivos do ponto de vista da sofisticação industrial, é importante ressaltar que o cenário subjacente é de desindustrialização e de mudanças nos métodos de produção da indústria. Portanto, os empregos que permanecem ou são criados pela indústria estão em ocupações que requerem cada vez menos habilidades motoras, que são a base das habilidades necessárias para as ocupações na indústria. Isso pode ser justificado por dois fatores principais: i) o aumento da dependência estrutural da indústria em relação a bens intermediários e finais importados e ii) o progresso tecnológico que economiza mão de obra.

Sobre o primeiro ponto, Coutinho, Laplane & Hiratuka (2003), Gala (2007), Salvato, Sant'anna & Silva (2008), Oreiro & Feijó (2010), Kannebley Jr., Prince & Scarpelli (2011), Gordon & Gramkow (2011) e Brene et al. (2014), Castro et al. (2017) encontraram evidências de um aumento na dependência estrutural da indústria brasileira em relação a bens importados para consumo intermediário. Esse aumento na dependência pode ser atribuído a diversos fatores, incluindo a abertura comercial na década de 1990, a implementação do Plano Real, o diferencial de competitividade em relação à produção internacional, a importação de produtos de fronteira tecnológica, que dificultou o processo de geração e difusão de tecnologias endógenas nacionais, a forte apreciação cambial da taxa real de câmbio nos anos 2000, o aumento do spread de juros domésticos em relação aos juros externos e a qualificação como "grau de investimento", que propiciou uma grande entrada de divisas, mantendo a moeda nacional valorizada, a expansão da taxa de crescimento da demanda interna, em um ambiente de câmbio apreciado, favorecendo o crescimento das importações em relação às exportações e, conseqüentemente, reduzindo o saldo da balança comercial.

Desta forma, o aumento da dependência estrutural por importações na indústria pode estar inibindo a criação de empregos e levando a indústria a contratar trabalhadores em ocupações que exigem mais habilidades sociais e cognitivas, em detrimento das habilidades motoras. As ocupações que requerem mais habilidades motoras podem estar localizadas em regiões estrangeiras onde os bens intermediários estão sendo produzidos. No entanto, apesar dessa tendência, a indústria ainda se caracteriza por ocupações com níveis mais elevados de habilidades motoras em comparação com habilidades cognitivas e sociais (ver Figuras 11 e 12).

Em relação ao segundo ponto, os avanços da tecnologia alteram o nível tecnológico dos processos produtivos (Brynjolfsson & McAfee, 2014; Frey & Osborne, 2017; Adamczyk, 2021). Esses avanços oferecem ganhos de escala, redução de custos e aumento da eficiência

produtiva (Autor, 2015; Frey & Osborne, 2017; WEF, 2016). Dessa forma, tarefas que anteriormente eram executadas por trabalhadores passam a ser automatizadas com a introdução de novas tecnologias, o que gera consequências no mercado de trabalho (Adamczyk, 2021). Essas consequências são denominadas na literatura como desemprego tecnológico e são mencionadas por diversos autores, incluindo Goldin & Katz (1998), Acemoglu & Autor (2011) e Firpo, Fortin & Lemieux (2011).

De acordo com Frey & Osborne (2017), as ocupações que estão mais sujeitas à automação são aquelas com trabalhadores de menor qualificação e remuneração, com tarefas que possuem maior possibilidade de serem padronizadas e codificadas em algoritmos. Tais ocupações são mais comuns no setor industrial, bem como nas atividades agropecuárias, florestais e da pesca. De fato, Adamczyk (2021) encontra evidências para o mercado de trabalho formal brasileiro de que a indústria obteve a maior variação negativa no emprego entre 2010 e 2018 devido a alterações nas tecnologias de produção, cerca de -12,6%, sendo considerado o setor mais afetado pela automação. Adamczyk (2021) ainda alerta que 75% dos empregos com maior propensão de serem automatizados são da indústria, o que representa 2,7 milhões de trabalhadores na RAIS. Na indústria em si, incluindo construção civil, 31,4% do emprego está em alta propensão à automação. Neste grupo encontram-se trabalhadores de obras, trabalhadores de confecção de roupas e de calçados, condutores de veículos, operadores de movimentação de cargas e assistentes administrativos em geral. Entre os menos automatizáveis estão os cargos de direção e organização de empresas, engenheiros, arquitetos e afins, técnicos em operações industriais e vendedores e demonstradores.

Em contrapartida, Frey & Osborne (2017) descrevem que ocupações que requerem o uso de criatividade na solução de problemas e inteligência social para comunicação e interação com equipes são apontadas como menos propensas à automação. De fato, Adamczyk (2021) encontra evidências para o mercado de trabalho brasileiro de que o emprego nos grupos que incluem os membros superiores do poder público, dirigentes e gerentes de organizações em geral e profissionais da ciência e das artes são os que apresentaram variação positiva no emprego devido a alterações nas tecnologias de produção. Entre as ocupações menos automatizáveis estão os trabalhadores em serviços de alimentação e hotelaria, vendedores e demonstradores e demais atividades comerciais. Por fim, as ocupações com menor propensão à automação são: diretores de empresas, engenheiros, profissionais da medicina, cientistas sociais e pesquisadores.

Desta forma, o progresso tecnológico poupador de mão de obra está levando a indústria a direcionar a contratação ou manutenção de trabalhadores em ocupações que são menos propensas a serem substituídas, como as ocupações que requerem mais habilidades sociais e cognitivas, ao invés das habilidades motoras. Esses resultados são ainda mais preocupantes ao identificar que algumas ocupações da indústria podem estar migrando para o setor informal ou para ocupações motoras menos intensas no setor formal. Sulzbach (2020) encontra evidências de que a probabilidade de ser informal está positivamente correlacionada apenas com a exigência de tarefas manuais no mercado de trabalho formal brasileiro. Por outro lado, o requerimento de tarefas cognitivas e rotineiras está negativamente correlacionado com a probabilidade de um indivíduo ser informal. Além disso, a autora ainda destaca que as tarefas cognitivas são as mais importantes para explicar a diferença salarial entre os setores formal e informal no Brasil.

Em resumo, a análise das habilidades desempenha um papel fundamental na compreensão da dinâmica da sofisticação industrial. Este capítulo apresentou evidências que indicam tanto resultados positivos quanto desafios no setor industrial, tais como o aumento do emprego e do número de estabelecimentos, bem como a desconcentração espacial da indústria. No entanto, os dados também revelaram uma diminuição na participação da indústria no emprego em relação a outros grandes setores, sugerindo um processo de desindustrialização precoce e mudanças no modo de produção.

Essa análise é importante como preparação para o próximo capítulo sobre convergência, uma vez que permite compreender as bases sobre as quais as transformações estão ocorrendo. Ao examinar como a indústria está se adaptando, quais habilidades são utilizadas e como a força de trabalho está evoluindo, pode-se identificar oportunidades e desafios. Além disso, entender as razões por trás da mudança na estrutura de habilidades requeridas na indústria, como a transição de habilidades motoras para cognitivas e sociais, é essencial para antecipar os impactos dessas transformações.

As análises de convergência, que são abordadas no próximo capítulo, têm o potencial de oferecer uma visão mais profunda sobre como diferentes regiões brasileiras estão se adaptando a essas mudanças. Elas podem ajudar a identificar quais regiões estão convergindo em termos de sofisticação industrial e quais estão ficando para trás. Isso é valioso para políticas públicas e tomadores de decisão, pois permite direcionar recursos e esforços para impulsionar a convergência e fortalecer a indústria em regiões menos desenvolvidas

3 METODOLOGIA

Este capítulo apresenta a metodologia adotada nesta tese. Inicialmente apresenta-se a estrutura teórica e analítica sobre os modelos de convergência e, em seguida, a estratégia empírica e de identificação empregada. Parte-se da hipótese de convergência da renda per capita entre as economias, testada por meio do estudo pioneiro de Baumol (1986). A hipótese do β -convergência sugere que o crescimento econômico de um país (ou região) depende do seu nível inicial. Logo, se o coeficiente de convergência for negativo e significativo, os países (ou regiões) menos desenvolvidas crescem mais do que países (ou regiões) mais desenvolvidas. A mesma abordagem será aplicada com o foco nas habilidades das ocupações da indústria. As seções seguintes apresentam os métodos de regionalização, a escolha da matriz espacial, os testes de robustez e de heterogeneidade e o banco de dados.

3.1 ASPECTOS TEÓRICOS

Estudos analisando o processo dinâmico de sofisticação industrial no Brasil são praticamente inexistentes. É ainda mais desafiador encontrar pesquisas que examinem as habilidades das ocupações requeridas pela indústria nas diferentes regiões em um contexto dinâmico. Para abordar essa lacuna, propõe-se a utilização da estrutura teórica e analítica dos modelos de convergência.

Uma das principais previsões teóricas dos modelos de crescimento neoclássico é que os níveis de renda de diferentes economias devem convergir a longo prazo (Cass, 1965; Koopmans, 1965). A hipótese subjacente a essa previsão de convergência é a presença de retornos decrescentes do capital, o que implica que a taxa de retorno do capital diminui à medida que o estoque de capital aumenta. Portanto, economias com baixa renda e escassez de capital são consideradas economias com altos retornos, o que resulta em maiores investimentos e, conseqüentemente, aceleração do crescimento econômico. Além disso, economias mais pobres têm a capacidade de realizar o *catching-up* tecnológico sem a necessidade de repetir todo o longo e custoso processo de Pesquisa e Desenvolvimento. Assim, adquirindo tecnologia de ponta, essas economias se aproximam da fronteira tecnológica e reduzem a distância entre elas e as economias mais ricas (Ellery Jr & Ferreira, 1996).

Embora a estrutura teórica e analítica dos modelos de convergência se refira à renda per capita, esse arcabouço é útil para encontrar evidências sobre o processo dinâmico pelo qual diferentes regiões, países ou grupos socioeconômicos caminham em direção à igualdade ou semelhança nos níveis de determinada variável a ser analisada ao longo do tempo, tais como renda *per capita* (Barro, 1991; Barro & Sala-I-Martin, 1992; Delgado, Porter & Stern, 2014; Aksoy, Tastan & Kama, 2019), bem-estar social (Royuela & Garcia, 2015; Hembran, Mukherjee & Haldar, 2020), educação (Gu, 2012; Guastella & Timpano, 2016), Inovação (Cui & Tang, 2023) e emissões de CO_2 (Rios & Gianmoena, 2018; Xue et al., 2021).

Portanto, se houver evidências de convergência de uma série, então a regressão do logaritmo da taxa de crescimento da variável deve possuir sinal oposto ao seu nível inicial. Por exemplo, se um país ou região possui a variável a ser analisada inicial (PIB, escolaridade, inovações, emissões de CO_2 e etc.) acima (abaixo) da média da amostra, então a taxa de crescimento dessa variável deve ser negativa (positiva) para que haja convergência. A mesma análise pode ser feita para a sofisticação da mão-de-obra industrial.

Se as evidências apresentadas no capítulo 2 apontam para o crescimento do emprego e, conseqüentemente, das habilidades nas regiões menos industriais do Brasil, existem ainda algumas barreiras nesse processo. Tais barreiras incluem externalidades positivas em mercados de trabalho mais densos, acesso ao mercado, custo de transporte e outros fatores que dificultam a transição das regiões industriais para as menos industriais. Portanto, é pertinente investigar empiricamente se as regiões que possuíam menor sofisticação industrial, representada pelas habilidades requeridas nas ocupações, estão se tornando mais sofisticadas. Em outras palavras, há convergência industrial por habilidades nas regiões? A sofisticação industrial das regiões está se tornando mais semelhante? Para que haja convergência das habilidades dos trabalhadores da indústria, a regressão do logaritmo da taxa de crescimento das habilidades da indústria deve ter um sinal oposto ao seu nível inicial, conforme preconiza a estrutura teórica e analítica dos modelos de convergência.

3.2 ESTRATÉGIA EMPÍRICA E DE IDENTIFICAÇÃO

Após o estudo pioneiro de Baumol (1986), diversas pesquisas surgiram testando empiricamente a abordagem do β -convergência (Barro, 1991; Barro, Sala-I-Martin & Blanchard, 1991; Barro & Sala-I-Martin, 1992). A hipótese do β -convergência sugere que o crescimento da renda *per*

capita de um país (ou região) depende do seu nível inicial. Se o coeficiente de convergência for negativo e significativo, os países (ou regiões) menos desenvolvidos crescem mais do que países (ou regiões) mais desenvolvidos. Barro, Sala-I-Martin & Blanchard (1991) sugeriram a seguinte equação de crescimento:

$$\left(\frac{1}{T}\right) \log \left(\frac{Y_t}{Y_0}\right) = c - \frac{(1 - e^{-\beta t})}{t} \log Y_0 + u_t \quad (3)$$

Em que a taxa de crescimento da renda per capita ($\log \left(\frac{Y_t}{Y_0}\right)$) depende do seu nível inicial ($\log Y_0$), condicionada sobre a taxa de crescimento exógena da tecnologia, sobre o valor estacionário por trabalhador efetivo e sobre o nível inicial de tecnologia.

O parâmetro c sumaria os parâmetros não observáveis, como os valores do *steady-state*. A velocidade de convergência para o *steady-state*, β , é a taxa na qual a economia representativa se aproxima de sua trajetória de crescimento no *steady-state* e, conseqüentemente, esse procedimento de análise de convergência é conhecido como β -convergência. Reformulando (3) para a convergência de habilidades da indústria, o modelo é dado por:

$$\left(\frac{1}{T}\right) \log \left(\frac{S_t}{S_0}\right) = c - \frac{(1 - e^{-\beta t})}{t} \log S_0 + u_t \quad (4)$$

Em que a taxa de crescimento das habilidades ($\log \left(\frac{S_t}{S_0}\right)$) depende do seu nível inicial ($\log S_0$). Uma análise mais simples estima o β por meio dos mínimos quadrados ordinários (MQO) em uma corte transversal de dados. A suposição é que as regiões consideradas pertencem a um sistema homogêneo. É factível que essa hipótese não se sustente. A solução é a utilização de um conjunto adicional de variáveis explicativas (X) que representam *proxies* para diferentes *steady-states* na regressão de corte transversal, passando de análise de convergência absoluta para convergência condicional (Islam, 2003).

Como não é fácil identificar tais variáveis explicativas representando o *steady-state* de cada região, uma alternativa empírica é o uso de métodos de dados em painel. Por meio da utilização de efeitos fixos, o *steady-state* de todas as regiões podem ser estimados da seguinte forma:

$$\log \left(\frac{S_t}{S_{t-1}}\right) = c_0 - \beta \log S_{t-1} + c_1(t) + u_t \quad (5)$$

Em que c_0 representa as características não observáveis das regiões e c_1 é um efeito fixo específico do tempo que afeta todas as economias. No entanto, as estimativas de dados em painel também apresentam alguns inconvenientes: se as bases de fatores causais no processo de crescimento das habilidades são persistentes, os efeitos transversais de longo prazo serão incluídos nos efeitos fixos da região, o que significa que o coeficiente explicativo do nível inicial das variáveis endógenas será muito menos informativo (Barro, 2000).

Entretanto, o método de dados em painel possibilita captar efeitos fixos não observáveis que iriam compor o termo de erro, enviesando as estimativas quando correlacionadas com a variável explicativa. A utilização da regressão com dados em painel tem como objetivo minimizar o viés e tornar o modelo consistente, ou seja, simétrico e com a menor variância possível. A justificativa é que a dinâmica da produção industrial e, conseqüentemente, da demanda por mão de obra da indústria não está, ao longo do período, relacionada simplesmente com os seus níveis iniciais incluídos na regressão, mas também com as características próprias de cada região. Além disso, com o efeito fixo é possível controlar características tecnológicas das indústrias e do emprego que são não observáveis nos municípios. Por fim, o efeito fixo permite comparar a convergência e seus efeitos apenas com a própria região. As técnicas de painel de efeitos fixos capturam como mudanças de séries temporais dentro de uma região afetam mudanças na sua taxa de crescimento ao longo do tempo.

Por outro lado, o uso de estimativas de painel de efeitos aleatórios foi evitado, pois eles são potencialmente não consistentes e, a longo prazo, as informações são basicamente capturadas nas estimativas MQO. A justificativa estatística é que a hipótese de efeito aleatório é muito forte e, dada a estrutura dos dados (emprego nas regiões), essa hipótese pode ser violada. Ou seja, o efeito aleatório assume que os efeitos não observáveis são iguais para todos os municípios. Essa hipótese pode não ser verdadeira, uma vez que há concentração das firmas e trabalhadores da indústria, o que pode impactar nos volumes de investimento em P&D, no *matching* entre trabalhadores e firmas, infraestrutura, acesso aos mercados, etc., fazendo com que as regiões possuam características diferentes entre si. Dessa forma, é muito forte assumir que a indústria da cidade do Crato – CE, por exemplo, possui ou é influenciada na mesma magnitude pelas mesmas variáveis que a indústria em São José dos Campos - SP ou até mesmo na cidade de São Paulo - SP.

3.3 A ABORDAGEM ESPACIAL

O β -convergência condicional infere o tempo de convergência das regiões e como isso acontece (Arbia, 2006). Reformulando em um contexto de habilidades requeridas pela indústria em dados em painel, o modelo é dado por:

$$\log \left(\frac{S_{i,t}}{S_{i,t-1}} \right) = -\beta \log(S_{i,t-1}) + \mu_i + \varphi_t + u_{i,t} \quad (6)$$

Em que i indica a região (unidade espacial), com $i = 1, 2, \dots, n$ e t é o período de tempo, $t = 1, 2, \dots, T$. O vetor $S_{i,t}$ contém as observações sobre o nível de habilidades da indústria para a região i no período t ; μ_i e φ_t são, respectivamente, o efeito fixo específico espacial (considera as características individuais das unidades espaciais não observáveis e invariantes no tempo) e o efeito fixo de tempo (choques comuns às indústrias ao longo do tempo). Além disso, o modelo de efeitos fixos permite controlar variáveis omitidas que se correlacionam com as variáveis dependentes e que são invariantes ao longo do tempo. Ambos efeitos podem contribuir para a variabilidade da variável dependente e $u_{i,t}$ é o termo de erro independente e identicamente distribuído para i e t , com média zero e variância constante.

Em alguns casos, os autores assumem que o termo de erro tem média zero e a mesma variância para todas as observações ($E(uu') = \sigma^2 I$). Essa suposição subjacente é particularmente crucial e restritiva se as observações forem organizadas espacialmente. De fato, se existem *spillovers* espaciais entre as regiões, ocasionados pela presença da autocorrelação espacial, a suposição formulada seria violada. Segundo LeSage & Pace (2009), ao investigar as unidades espaciais há grande probabilidade de a amostra apresentar autocorrelação espacial. Ao se tratar de atividade econômicas como a indústria, que usualmente se concentra espacialmente, exige-se a incorporação desse efeito no modelo, no sentido de evitar problemas advindos de omissão de variável relevante, por exemplo (Arbia, 2006).

Em outras palavras, a existência de *spillovers* espaciais pode causar correlações entre observações que estão geograficamente próximas umas das outras. Isso pode ser problemático, uma vez que as técnicas estatísticas e econométricas pressupõem que as observações são independentes umas das outras (hipótese de exogeneidade). Quando essa suposição é violada, é necessário usar métodos que levem em conta a estrutura de dependência espacial dos dados para obter resultados mais precisos e confiáveis.

Os testes de dependência e autocorrelação espacial, como LMI (Lagrange Multiplier lag), RLMI (Robust Lagrange Multiplier lag), LMe (Lagrange Multiplier Error), e RLMe (Robust Lagrange Multiplier Error), são ferramentas estatísticas usadas para avaliar se há dependência espacial ou autocorrelação espacial nos resíduos das regressões OLS. O LMI (Lagrange Multiplier lag) é usado para verificar a presença de autocorrelação espacial em um modelo de regressão espacial do tipo SAR (defasagem espacial), avaliando se os erros do modelo de regressão estão correlacionados espacialmente. O teste é baseado no vetor escore e na matriz de informação sob a hipótese nula de $\rho = 0$ e hipótese alternativa de $\rho \neq 0$. Entretanto, os testes de multiplicador de Lagrange não apresentam muito poder se houver má especificação do teste. Neste caso, se $\rho \neq 0$, o teste baseia-se em uma distribuição qui-quadrado não centrada, acarretando a rejeição da hipótese nula de $\rho = 0$ com muita frequência. Para lidar com esse problema, o RLMI (Robust Lagrange Multiplier lag) é uma versão robusta do teste LMI, incorporando um fator de correção com o propósito de superar a má especificação local do modelo.¹³ O LMe (Lagrange Multiplier Error) também é usado para verificar a autocorrelação espacial em modelos de regressão espacial do tipo SEM (erro espacial). O teste é baseado no vetor escore e na matriz de informação sob a hipótese nula de $\lambda = 0$ e hipótese alternativa de $\lambda \neq 0$. O teste LMe apresenta a mesma limitação do LMI, porém o primeiro tem a dificuldade adicional de não identificar a fonte de autocorrelação espacial quando a hipótese nula é rejeitada¹⁴. O RLMe (Robust Lagrange Multiplier Error) é a versão robusta do teste LMe, projetada para lidar com as limitações sobre o poder do teste, incorporando um fator de correção sobre a má especificação. Em outras palavras, procura controlar a influência da autocorrelação na variável dependente sobre o teste LMe (Anselin, 1988; Anselin et al. 1996; Anselin, 2005).¹⁵

Os testes citados acima são usados na análise de regressão espacial para verificar a autocorrelação espacial nos resíduos, testando a hipótese nula de ausência de autocorrelação. Os resultados desses testes ajudam a determinar se a estrutura espacial deve ser considerada ao interpretar os resultados de um modelo de regressão espacial. A principal diferença entre os dois testes está no escopo da autocorrelação espacial avaliada. O LMI avalia a autocorrelação espacial global por meio da defasagem espacial, enquanto o LMe está mais focado nos termos

¹³ Anselin e Florax (1995) mostraram que o RLMI tem bom desempenho em relação ao poder do teste. Anselin e Rey (1991) encontraram evidências de que o RLMI é mais poderoso que o LMe, pois a consequência de ignorar a autocorrelação espacial na forma de defasagem é mais séria que na forma de erro.

¹⁴ Para esse caso, não se sabe se o modelo alternativo é do tipo SAR ou SEM (Almeida, 2012).

¹⁵ Em pequenas amostras o RLMe é poderoso, mas o poder do teste é menor do que o do LMe quando realmente não existe autocorrelação na forma de defasagem, mas somente autocorrelação na forma de erro (Anselin & Florax, 1995; Anselin & Bera, 1998).

de erro do modelo. Além disso, o LMe pode ser mais apropriado quando se deseja avaliar a autocorrelação espacial específica dos erros, deixando de lado a contribuição das variáveis explicativas do modelo. Em resumo, ambos os testes LMI e LMe são usados para detectar a autocorrelação espacial nos resíduos de modelos de regressão espacial, mas o LMe se concentra especificamente na autocorrelação dos termos de erro. A escolha entre eles dependerá das perguntas de pesquisa e das características dos dados. Os resultados desses pré-testes podem orientar na escolha do modelo econométrico adequado e na interpretação dos resultados, especialmente quando a presença de autocorrelação espacial pode afetar a precisão das estimativas e inferências.

Neste contexto, utilizou-se uma especificação alternativa para estimar a convergência condicional dos níveis de habilidades na indústria envolvendo análise econométrica de painel espacial. A literatura de econometria espacial tem exibido um interesse crescente na especificação e estimação das relações econométricas com base em painéis espaciais para investigar a convergência regional, como em Arbia & Piras (2005), Arbia, Baseile & Piras (2005), Le Gallo & Dall'Erba (2006), Esposti & Bussoletti (2008), Arbia, Le Gallo & Piras (2008), Diop (2018), Aksoy, Tastan & Kama (2019) e Xue et al. (2021). Esse interesse pode ser explicado pela maior disponibilidade de conjuntos de dados em que é possível identificar as unidades espaciais ao longo do tempo e pelo fato de que os dados em painel oferecem mais vantagens de modelagem em comparação com dados transversais (Elhorst, 2010). Além do maior número de graus de liberdade, uma das grandes vantagens da abordagem de dados em painel para convergência é a correção do problema da variável omitida, que pode estar presente nos modelos de dados em painel e nos modelos *cross-section*. Modelar o efeito específico das regiões (efeitos individuais) permite considerar diferenças tecnológicas entre regiões ou outro fenômeno não observável (Islam, 2003).

Para saber qual especificação é a mais apropriada para a convergência condicional para um determinado processo de geração de dados, adotou-se a estratégia descrita em Arbia (2006), LeSage (2009) e Elhorst (2010), partindo de uma especificação geral para específica em modelos de painel espacial:

$$\log\left(\frac{S_{i,t}}{S_{i,t-1}}\right) = \beta \log(S_{i,t-1}) + \rho \sum_{j=1}^n w_{ij} \log\left(\frac{S_{j,t}}{S_{j,t-1}}\right) + \theta \sum_{j=1}^n w_{ij} \log(S_{j,t-1}) + \mu_i + \varphi_t + u_{i,t} \quad (7)$$

com

$$u_{i,t} = \lambda \sum_{j=1}^n w_{ij} u_{j,t} + \varepsilon_{i,t} \quad i = 1, \dots, n \quad t = 1, \dots, T \quad (8)$$

e

$$\varepsilon_{i,t} \sim i. i. d. (0, \sigma_\varepsilon^2) \quad (9)$$

Em que $S_{i,t}$ contém as observações sobre o nível de habilidades da indústria para a região i no período t ; o parâmetro β representa a convergência das habilidades na indústria; o parâmetro ρ captura a sensibilidade da variável endógena sobre a variável defasada espacialmente (taxa de crescimento do nível de habilidades da indústria dos vizinhos); θ representa as variáveis exógenas defasadas espacialmente (nível de habilidades da indústria dos vizinhos) e λ é o parâmetro de erro espacial, ou seja, é um coeficiente escalar que indica a intensidade da autocorrelação espacial entre os resíduos da equação. w_{ij} representa cada elemento da matriz de peso espaciais W . Os pesos espaciais (w_{ij}) capturam o efeito vizinhança e diferem de zero quando as regiões i e j são vizinhas. Por convenção, nenhuma região pode ser sua vizinha, então todos os elementos da diagonal principal de W são iguais a zero ($w_{ij} = 0$). Os demais parâmetros seguem a especificação da equação (6).

Se $\lambda = 0$, tem-se o modelo Spatial Durbin Model (SDM), se $\rho \neq 0$ e $\theta = 0$, tem-se o modelo espacial autoregressivo (SAR), que pode ser considerado como uma média espacialmente ponderada do nível de habilidades da indústria de todos os vizinhos da região, i 's. Se $\theta = -\beta\rho$, tem-se o modelo de Erro Espacial (SEM), que mensura o efeito médio dos erros dos vizinhos em relação ao resíduo da região em questão. Para encontrar o modelo espacial com melhor ajustamento aplicou-se o teste de Wald, que permite verificar que se a hipótese nula de os parâmetros $\theta = 0$ e $\rho \neq 0$ (SDM = SAR) ou $\theta = -\beta\rho$ (SDM = SEM) serem iguais a zero, indicando que uma abordagem espacial menos complexa (SAR e SEM) é preferível a uma mais complexa (SDM). Caso a hipótese nula não seja rejeitada, a escolha do modelo SAR ou SEM se dá pelo critério de seleção AIC.

Em um cenário espacial, o efeito de uma mudança de variável explicativa em uma determinada unidade afeta não apenas essa unidade, mas também seus vizinhos (LeSage e Pace, 2009). Dado que o operador inverso representa o multiplicador da matriz espacial, como apresentado em (10), isso implica na existência de efeitos marginais diretos, indiretos e totais.

$$\left[\frac{\partial Y}{\partial X_{nk}} \right] = (I - \rho W)^{-1} \begin{bmatrix} \beta_k & \dots & w_{1n}\theta_k \\ \vdots & \ddots & \vdots \\ w_{n1}\theta_k & \dots & \beta_k \end{bmatrix} \quad (10)$$

Desta forma, o β que representa os efeitos marginais totais será o β -convergência das habilidades da indústria para os modelos SAR e SDM quando estes forem os modelos escolhidos. Os modelos espaciais são estimados pelo método de máxima verossimilhança. O teste de restrição de parâmetros (λ , θ e ρ) é utilizado para escolher o modelo com melhor ajuste da representação do processo espacial. As regressões espaciais são do tipo painel de dados, sendo estimadas entre os anos de 2003 a 2019 com erro padrão robusto. O erro padrão robusto é calculado ajustando a matriz de covariância dos erros, levando em consideração a heterocedasticidade. Isso permite que os resultados das análises sejam mais confiáveis quando a suposição de homocedasticidade não é satisfeita.

Este modelo baseia-se na ideia de que se as RGI são estruturalmente idênticas, todas têm acesso à mesma tecnologia e também são caracterizadas pelo mesmo estado estacionário, diferindo apenas em suas condições iniciais. O parâmetro β está vinculado à chamada “Velocidade Anual Implícita de Convergência (φ)” e ao indicador de “Meia-Vida” para o estado estacionário (Arbia, Le Gallo & Piras, 2008). Para os propósitos desta tese, os indicadores ajudam a compreender o ritmo pelo qual as RGI estão se aproximando em termos de habilidade.

A Velocidade anual implícita de convergência, representada por φ (phi), mede a taxa na qual as RGI em análise estão convergindo em termos de habilidades. De acordo com Arbia, Le Gallo & Piras (2008) o indicador é calculado da seguinte forma:

$$\varphi = -\ln(1 + \beta)/T \quad (11)$$

Sendo β o parâmetro de convergência estimado nas regressões e T o número de anos da análise. Se φ for positivo, indica que as RGI estão convergindo, ou seja, as regiões menos industrializadas estão crescendo mais rapidamente em termos de habilidade do que as RGI mais industrializadas. Se φ for zero, isso sugere que não há convergência: as habilidades nas

indústrias nas RGI estão mantendo a mesma diferença de habilidades ao longo do tempo. Se φ for negativo, indica divergência, o que significa que as habilidades nas indústrias nas RGI mais industrializadas estão crescendo mais rapidamente em termos de habilidade do que as RGI menos industrializadas.

A Meia-Vida indica o número de anos necessários para que a indústria de uma RGI específica alcance a metade da diferença entre seu nível de habilidade inicial e o nível de habilidade da indústria da RGI de referência (geralmente a RGI mais industrializada) em um processo de convergência. Segundo Arbia, Le Gallo & Piras (2008) o indicador é calculado da seguinte forma:

$$\text{Meia – Vida} = \ln(2)/\varphi \quad (12)$$

Sendo φ o indicador de velocidade anual implícita de convergência. O indicador fornece uma medida do período que levará para reduzir pela metade a diferença de habilidades entre as RGI, assumindo a taxa de convergência estimada pela Velocidade Anual Implícita de Convergência (φ). Quanto mais curta a Meia-Vida, mais rápido as indústrias das RGI convergem, e vice-versa.

Em resumo, φ e a Meia-Vida são ferramentas importantes para avaliar a dinâmica da convergência de habilidades na indústria. Os indicadores permitem entender se as indústrias nas RGI estão se aproximando ou se afastando em termos de habilidades e a que ritmo isso está ocorrendo. Esses conceitos são amplamente utilizados em análises de crescimento econômico e políticas de desenvolvimento para avaliar o progresso econômico das regiões e dado a sua importância, serão empregados nesta tese.

3.4 HETEROGENEIDADE SETORIAL

O nível de habilidades da indústria em uma região depende do tipo de indústria que está ali instalada. Se uma indústria possui métodos de produção mais rudimentares, é de se esperar que demande trabalhadores em ocupações menos sofisticadas e complexas. Desta forma, espera-se que a β -convergência condicional de habilidades na indústria nas RGI seja diferente para cada tipo de indústria. Para verificar a heterogeneidade industrial do β -convergência condicional parte-se da especificação geral para modelos de painel espacial, representada pelas equações (7), (8) e (9), com os setores sendo separados em quatro grupos: 1) Agroindústria e Não Agroindústria e; 2) Indústria Intensiva em Capital e Indústria Intensiva em Trabalho.

A ideia por trás da separação da agroindústria se deve ao crescimento deste segmento industrial. De acordo com Favro & Alves (2020), a agroindústria apresentou crescimento médio de 9% no Valor da Transformação Industrial (VTI) entre 1996 a 2017, contribuindo de maneira significativa para a indústria. Favro & Alves (2020) ainda destacam que entre 2006 e 2016 este segmento teve participação média de 35% no emprego formal da indústria. Os setores que representam esse segmento são alimentos, têxtil e de madeira e móveis (Santos, 2014). Entretanto, esses setores são classificados com média-baixa e baixa intensidade tecnológica pela OCDE, ou seja, fazem pouco, ou nenhum, investimento em P&D. Porém, são setores expressivos em número de emprego (Morceiro, 2018). Desta forma, espera-se que este segmento demande ocupações com habilidades motoras e sociais em detrimento de ocupações com habilidades cognitivas.

A construção é baseada nos trabalhos empíricos que classificaram os setores que compõem a agroindústria. O ponto comum desses trabalhos é que eles consideram a indústria de alimentos, bebidas e tabaco nos conceitos de agroindústria. A inserção dos demais setores depende dos objetivos, da base de dados e da metodologia empregada no estudo (Favro & Alves, 2020). Com base na literatura revisada, apresentam-se duas classificações da agroindústria para o Brasil: uma considera o sentido amplo; outra, o sentido restrito. A principal diferença entre as duas é que a versão restrita contempla as indústrias que se ocupam da primeira e da segunda transformações da matéria-prima agropecuária. Esse critério exclui os itens consumidos no varejo depois de outras etapas da indústria, que, por vezes, usa componentes não derivados da agropecuária, como tintas, plásticos e couro sintético (Santos, 2013). Já o conceito amplo abrange as atividades industriais que realizam também transformações adicionais na matéria-prima.

Para essa tese foi utilizada a classificação de agroindústria de sentido amplo (Apêndice B – Tabela B.1), pois considera as atividades de fabricação que estão inseridas dentro da indústria de transformação. Como resultado final da classificação de sentido amplo, Favro & Alves (2020) obtiveram 100 subclasses, inseridas nas seguintes divisões: fabricação de alimentos, bebidas e fumo, fabricação de produtos têxteis, confecção de artigos do vestuário e acessórios, preparação de couros e fabricação de artefatos de couro, fabricação de produtos de madeira, fabricação de celulose, papel e produtos de papel, fabricação de coque, de produtos derivados do petróleo e de biocombustíveis e fabricação de móveis.

A separação da indústria intensiva em capital e intensiva em trabalho se deve à evidência de que os setores classificados como sendo de média e alta intensidade tecnológica são condizentes com as indústrias intensivas em capital e as indústrias de média e baixa intensidade tecnológica são condizentes com as indústrias intensivas em trabalho (Morceiro, 2018). A indústria trabalho-intensiva é caracterizada pela própria característica do processo produtivo desse segmento, ou seja, pela menor aplicação de investimento em tecnologia. Segundo Nogueira (2017), esse fato se deve à atuação mais presente dos sindicatos na obtenção e manutenção de maiores salários e emprego, fato que tende a reduzir os investimentos em P&D.

Além disso, ao analisar as características da indústria intensiva em capital e intensiva em trabalho entre 2007 a 2014, Nogueira (2017) indica que a primeira possui características que denotam uso de mão-de-obra melhor qualificada, com salários maiores, escolaridade média maior e tempo de serviço (experiência ocupacional) maior. Desta forma, por possuir uma mão-de-obra mais qualificada, esse segmento apresenta produtividade maior do que a indústria intensiva em trabalho. Além disso, a indústria intensiva em capital é mais concentrada espacialmente em relação à indústria intensiva em trabalho (Silva & Neto, 2007). Desta forma, espera-se que o segmento da indústria intensiva em capital demande ocupações com habilidades cognitivas e motoras em detrimento das habilidades sociais e o segmento da indústria intensivo em trabalho demande ocupações com habilidades motoras e sociais em detrimento de ocupações com habilidades cognitivas.

Para essa tese foram utilizadas as classificações de indústrias intensivas em capital e intensivas em trabalho desenvolvidas por Nogueira (2017), que incluiu setores que não estavam anteriormente classificados nas pesquisas de Silveira Neto (2005) e Lisboa et al. (2010). A classificação completa pode ser encontrada no Apêndice B – Tabela B.2.

3.5 HETEROGENEIDADE ESPACIAL

O conceito de convergência condicional também está relacionado com a noção de “clube de convergência”. Segundo Islam (2003), uma propriedade padrão da Teoria de Crescimento Neoclássica é a unicidade do *steady-state* e a noção usual de convergência assume essa unicidade. No caso de convergência absoluta, há apenas um nível de equilíbrio para o qual todas as regiões se aproximam. No caso de convergência condicional, o equilíbrio difere de acordo com a região e cada economia em particular se aproxima de seu próprio, mas único, equilíbrio.

Em contraste, a ideia de clube de convergência é baseada em modelos que produzem múltiplos equilíbrios. Qual desses diferentes equilíbrios uma região alcançará depende de sua posição inicial ou de algum outro atributo. Um grupo de regiões pode ter um determinado equilíbrio se compartilham a mesma localização inicial ou a algum atributo correspondente a esse equilíbrio. Isso produz clubes de convergências.

Para a análise de heterogeneidade espacial, considerou-se também a estratégia de Arbia (2006), LeSage (2009) e Elhorst (2010), partindo de uma especificação geral para modelos de painel espacial com uma adaptação com dummies para captar a heterogeneidade espacial de acordo com os agrupamentos citados acima. O modelo ficou da seguinte forma:

$$\begin{aligned} \log\left(\frac{S_{i,t}}{S_{i,t-1}}\right) &= \beta \log(S_{i,t-1}) + \beta_k \sum_{k=1}^K d \times \log(S_{i,t-1}) \\ &+ \theta \sum_{j=1}^n w_{ij} \log(S_{j,t-1}) + \rho \sum_{j=1}^n w_{ij} \log\left(\frac{S_{j,t}}{S_{j,t-1}}\right) \\ &+ \theta_k \sum_{k=1}^K d \times \sum_{j=1}^n w_{ij} \log(S_{j,t-1}) + \mu_i + \varphi_t + u_{i,t} \end{aligned} \quad (13)$$

com

$$u_{i,t} = \lambda \sum_{j=1}^n w_{ij} u_{j,t} + \varepsilon_{i,t} \quad i = 1, \dots, n \quad t = 1, \dots, T \quad (14)$$

e

$$\varepsilon_{i,t} \sim i. i. d. (0, \sigma_\varepsilon^2) \quad (15)$$

Em que $S_{i,t}$ contém as observações sobre o nível de habilidades da indústria para a região i no período t ; o parâmetro β_k representa a diferença da convergência das habilidades na indústria para cada classe de tamanho (k) em relação ao classe de tamanho de referência (capturado pelo primeiro β); ρ é um parâmetro escalar espacial que captura a taxa de crescimento do nível de habilidades da indústria dos vizinhos; θ_k representa a diferença do nível de habilidades da indústria dos vizinhos para cada classe de tamanho (k) em relação ao classe de tamanho de referência (capturado pelo primeiro θ); λ é o parâmetro de erro espacial e; d são variáveis dummy (0 e 1) multiplicativas que qualificam o nível de habilidades da indústria para as regiões pertencentes a cada classe de tamanho (k). Esta especificação permite que o processo de

convergência e os efeitos das variáveis condicionantes sejam diferentes entre as classes de tamanhos. Os demais parâmetros seguem a especificação da equação (7).

Para este estudo, os clubes de convergência são determinados por meio da análise do quintil de emprego formal. Esse procedimento permite verificar se a dinâmica do β_k convergência varia a depender das características do mercado de trabalho nas regiões onde há concentração do emprego. As regiões industriais devem apresentar importantes diferenças institucionais e estruturais em suas escalas econômicas, mercado de trabalho e infraestrutura, que podem impactar de forma heterogênea a convergência das habilidades. Por isso, faz-se necessário uma análise de heterogeneidade espacial da convergência das habilidades da indústria.

3.5.1 Classe de tamanho via quintil de emprego da indústria

Com o propósito de captar os efeitos das economias de aglomeração sobre a convergência condicional de habilidades, os clubes de convergência serão determinados pelo quintil de emprego formal da indústria em 2019. Como apresentado na seção 2.1, as regiões podem ser beneficiadas pelas economias de aglomeração, que podem ser fonte para os retornos crescentes de escala. Ou seja, a indústria individual pode operar sob retornos constantes à escala, mas a existência de efeitos *spillovers* na região pode proporcionar retornos crescentes em comparação com a indústria de outras regiões. Os *spillovers* podem ocorrer via o *learning by doing* à la Arrow (1971) e Romer (1990) ou via efeito *sharing, matching e learning*, de Duranton & Puga (2005).

As economias de aglomeração são representadas por quintil de emprego (tamanho). Espera-se que o β -convergência seja maior nas regiões com alta densidade de emprego industrial, ou seja, nas regiões mais aglomeradas. Espera-se que regiões com maior densidade industrial desfrutem de níveis mais altos de economias de aglomeração, níveis mais altos de produtividade e, como resultado, demande trabalhadores mais sofisticados em suas indústrias.

3.6 ESCOLHA DA MATRIZ ESPACIAL

A dinâmica da distribuição da dimensão espacial das variáveis também é relevante. Apesar da recomendação de uso da teoria nos modelos de econometria espacial, especialmente relacionados à estrutura teórica a priori na escolha das matrizes espaciais (Corrado & Fingleton,

2012), este estudo seleciona as matrizes com base no critério “*goodness-of-fit*” sugerido por Stakhovych & Bijmol (2009), Zhang & Yu (2018) e Kubara & Kopczewska (2023). A utilização do critério de informação de Akaike (AIC) para avaliar a qualidade de modelos econométricos espaciais com um número diferente de vizinhos mais próximos incluídos na matriz de ponderação espacial W é de suma importância em dois casos: i) ao estimar o modelo em dados de pontos geolocalizados sem orientação explícita sobre o valor ideal de vizinhos mais próximos, ou seja, sem uma base teórica robusta a priori e ii) ao lidar com diferentes padrões espaciais, pois uma matriz W única generaliza diversas estruturas espaciais que podem estar presentes na análise em questão (Kubara & Kopczewska, 2023). Zhang & Yu (2018) propõem um método de seleção de matrizes baseado no critério de Mallows. Entretanto, para alguns casos como, por exemplo, quando o verdadeiro modelo tem parâmetros espaciais diferentes de zero, o critério de Mallows tem performance pior para a seleção da verdadeira matriz W .

Logo, o valor do critério de informação AIC de cada modelo é calculado sendo que o modelo que exibe o menor AIC tem a maior probabilidade de conter a estrutura de vizinhança correta. Esse resultado é equivalente à maximização do valor da log-verossimilhança. Ao minimizar o AIC para um conjunto de modelos concorrentes, pode-se encontrar o número ótimo de vizinhos mais próximos que garante o melhor ajuste (Kubara & Kopczewska, 2023)¹⁶.

A estrutura espacial utilizada nesta tese envolve 510 RGI e cada RGI possui na média 5,53 vizinhos contíguos. A RGI que possui o maior número de vizinhos é a RGI de Juazeiro – BA com 13 vizinhos contíguos. Logo, existem poucas relações de vizinhanças com essa estrutura espacial agregada, uma vez que o espaço geográfico está agregado em comparação ao nível municipal, em que a média de vizinhos contíguos é maior, cerca de 5,75 vizinhos¹⁷. Seguindo a recomendação de Kubara & Kopczewska (2023), os modelos são estimados utilizando a matriz de pesos espaciais *k-nearest neighbors* (*knn*), com o número de vizinhos variando de 1 a 30. Esse intervalo mais amplo permite encontrar a matriz de relação espacial que tenha a maior probabilidade de estar correta. Logo, assume-se como *upper bound* mais que o dobro da relação máxima de vizinhança observada nos dados espaciais e como *lower bound* espera-se que haja ao menos uma relação de vizinhança para cada RGI.

¹⁶ Os autores encontraram resultados robustos por meio de simulação computacional. Além disso, forneceram evidências práticas de que uma matriz W mal especificada pode resultar em um viés de 20% dos parâmetros do modelo.

¹⁷ O município de São Paulo – SP é o município com maior número de vizinhos contíguos, 21.

3.7 TESTES DE ROBUSTEZ

Um outro indicador de convergência envolve a distribuição da variável em dois períodos de tempo diferentes. A medida mais básica, a chamada σ -convergência (Quah, 1993a), geralmente é dada pelo desvio padrão ou pelo coeficiente de variação (CV) nesses dois diferentes períodos de tempo. A σ -convergência permite determinar se uma variável está se tornando cada vez mais semelhante entre as regiões estudadas. Como Quah (1993a) explicou, a β -convergência é condição necessária, mas não suficiente, para alcançar σ -convergência e, portanto, a convergência β e σ precisam ser consideradas em conjunto (Sala-I-Martin, 1996).

Além do σ -convergência, há uma segunda linha de análise por meio da abordagem da dinâmica da distribuição. A abordagem de regressão é substancialmente pouco informativa, devido à sua ênfase no comportamento de uma economia representativa. Desta forma, falha em revelar a dinâmica da distribuição transversal, ou seja, de fornecer informações sobre como uma parte da distribuição se comporta em relação à outra em dois períodos de tempo (Quah, 1993a, 1996a, 1996c). Em contraste, a abordagem mais recente examina diretamente a distribuição transversal das variáveis em questão (PIB, escolaridade, inovações, emissões de CO_2 e etc) como análise complementar à σ -convergência. Em particular, recorre a kernels estocásticos para captar o comportamento de toda a distribuição transversal dessas variáveis à medida que evolui ao longo do tempo, fornecendo informações tanto sobre a mudança em sua forma externa quanto sobre a dinâmica intradistributiva (Magrini, 2009).

Para a estimativa de densidade do kernel, todas as variáveis são expressas em relação à média nacional. Esse procedimento permite a abstração de mudanças na média quando se observa como a distribuição muda. Com o propósito de facilitar a comparação, utiliza-se o logaritmo das variáveis relativas (habilidades e escolaridades). Desta forma, todos os valores podem ser interpretados como a diferença em termos proporcionais em relação à média nacional.

A estimativa de densidade do kernel \hat{f}_h , de uma densidade univariada f , com base em uma amostra aleatória X_1, X_2, \dots, X_n de tamanho n é:

$$\hat{f}_h(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - X_i}{h}\right) \quad (16)$$

Em que h é o parâmetro de suavização da largura de banda do kernel e K é o kernel, que é uma função de densidade de probabilidade simétrica. O teste de Silverman (1986) precisa ser aplicado para verificar se há uni ou multimodalidade nas densidades estimadas e ver como a dinâmica de toda a distribuição muda entre o início e término do período. Desta forma, o teste de Silverman determinará se há convergência nas variáveis relativas na forma logarítmica.

Segundo Royuela & García (2015), para uma amostra aleatória bivariada X_1, X_2, \dots, X_n extraída de uma densidade f , a estimativa de densidade bivariada do kernel é definida por:

$$\widehat{f}_H(x) = \frac{1}{n} \sum_{i=1}^n K_H(x - X_i) \quad (17)$$

onde $x = (x_1, x_2)^T$; e $X = (X_1, X_2)^T$. K é novamente a função do kernel; H é a matriz de largura de banda, que é simétrica e definida positivamente¹⁸; e

$$K_H = |H|^{-\frac{1}{2}} K(H^{-\frac{1}{2}}x) \quad (18)$$

Também apresenta-se a representação gráfica tridimensional da densidade bivariada estimada e um gráfico de contorno. A diagonal principal nestes gráficos representa a persistência, uma vez que os elementos da distribuição transversal permanecem onde começaram. A convergência perfeita é encontrada se a maior parte do gráfico estiver em torno da média do eixo y (2019) e paralela ao eixo x (2003). Finalmente, a análise intra-distribuição pode ser realizada buscando a formação de modas separados, um sinal de polarização (estratificação) na distribuição das variáveis.

Como o objetivo principal deste estudo é analisar a convergência e padrões de crescimento das habilidades das ocupações, todas as possíveis técnicas e fontes de convergência são inspecionadas para obter resultados robustos, seguindo o estudo de Magrini (2007) e Royuela & García (2015). Examinam-se a distribuição das variáveis ao longo tempo, β -convergência, σ -convergência e o espaço do comportamento das variáveis. Além disso, as análises são

¹⁸ Para estimativas de densidade de kernel univariada e bivariada, foi utilizada a função de densidade gaussiana. Para selecionar a largura de banda univariada e bivariada das estimativas de densidade do kernel foi utilizada a metodologia de plug-in proposta por Sheather & Jones (1991).

complementadas com o kernels estocásticos (Royuela & García, 2015) e os testes de heterogeneidade setorial e espacial.

3.8 BASE DE DADOS

As regressões espaciais são do tipo painel de dados, ao nível das 510 Regiões Geográficas Imediatas (RGI) do país, segundo a classificação oficial (Brasil, 2017), sendo estimadas entre os anos de 2003 e 2019. As RGI substituíram as microrregiões criadas em 1980, considerando as transformações econômicas, demográficas, políticas e ambientais ocorridas ao longo das últimas décadas. Foi operacionalizada a partir de elementos concretos (rede urbana, classificação hierárquica dos centros urbanos, detecção dos fluxos de gestão, entre outros), capazes de distinguir espaços regionais em escalas adequadas.

De acordo com o Brasil (2017):

As Regiões Geográficas Imediatas têm na rede urbana o seu principal elemento de referência. Essas regiões são estruturas a partir de centros urbanos próximos para a satisfação das necessidades imediatas das populações, tais como: compras de bens de consumo duráveis e não duráveis; busca de trabalho; procura por serviços de saúde e educação; e prestação de serviços públicos, como postos de atendimento do Instituto Nacional do Seguro Social - INSS, do Ministério do Trabalho e de serviços judiciários, entre outros. (Brasil, 2017, pg.20).

O problema da escala espacial, ou seja, da sensibilidade dos resultados ao nível de agregação geográfica dos dados faz parte do Problema da Unidade de Área Modificável (MAUP). Além do problema de escala, o MAUP é caracterizado pelo problema de zoneamento, ou seja, os dados apresentam diferentes respostas de acordo com a forma de combiná-los em zonas (Guimarães & Almeida, 2017). Os níveis de agregação e a organização espacial em zonas afeta a magnitude de várias medidas associadas às unidades, aos coeficientes de autocorrelação espacial e aos parâmetros do modelo de regressão (Anselin, 1988). Portanto, o MAUP e seus possíveis efeitos devem ser levados em consideração nos trabalhos com estatística espaciais. Nesse sentido, é importante escolher adequadamente o nível regional para o fenômeno analisado e selecionar formas de agregação mais universalmente aceitas, o que permite uma melhor comparação de resultados em relação ao uso de divisões *ad hoc*.

Essa preocupação está em linha com os resultados do trabalho de Beaudry & Schiffauerova (2009). Os autores indicaram que muito das diferenças nos resultados de estudos que analisam

as vantagens e desvantagens de estruturas regionais especializadas ou diversificadas se deve ao uso de diferentes escalas geográficas de agregação.

Assim, tendo em conta que o fenômeno estudado se refere às habilidades ocupacionais na indústria regional, tem-se como pressuposto inicial que cada região industrial surge no entorno de um mesmo polo econômico e de trabalhadores qualificados. Isso é que o apontam Bresch & Lissoni (2001) e Araújo (2014), ao indicarem, para o caso das regiões inovadoras, que os colaboradores formais de empresas e outros mecanismos não formalizados de fluxos de conhecimento (como a mobilidade de trabalhadores e *spillovers* locais de conhecimento) ocorrem preferencialmente em níveis regionais urbanos. Portanto, pode-se supor que o nível geográfico mais adequado para a análise da indústria seja o que não fragmenta as grandes cidades em mais de uma unidade de observação.

Nesse sentido, para o estudo das habilidades da indústria nas regiões é particularmente adequado o uso de um recorte espacial que abrange as áreas urbanas e industriais de forma similar às áreas metropolitanas estatísticas dos Estados Unidos (*Metropolitan Statistical Areas – MSA*). Isso restringe possíveis problemas MAUP porque permite uma análise de elementos espaciais mais homogêneos e facilita a comparação de resultados de estudos quantitativos. Ao mesmo tempo, um recorte com essas características possibilita analisar unidades geográficas como, por exemplo, alguns aglomerados urbanos que ultrapassam os limites espaciais dos municípios. No entanto, tal recorte geográfico específico não está disponível atualmente para o caso brasileiro.

É importante ressaltar que ao escolher um nível geográfico de análise sempre se incorre em arbitrariedades. A escolha do nível regional deste estudo deve-se a alguns motivos. Seguindo a argumentação de Araújo (2014), foram descartados os níveis municipais, de unidades da federação e grandes regiões. Um estudo regional para as unidades da federação ou grandes regiões apresentaria diversas dificuldades: pequeno espaço amostral; grandes áreas heterogêneas e desconexas economicamente, especialmente nos grandes estados da federação, com áreas espaciais muito díspares. Já a exclusão do uso do nível municipal para a análise refere-se ao alcance expandido da atividade econômica, ou seja, a atividade econômica não respeita os limites municipais, especialmente no caso de algumas metrópoles que são compostas por dezenas de municípios que interagem como uma única unidade econômica. Gonçalves (2007) fundamenta sua opção pelo nível microrregional em seu estudo sobre inovação,

indicando que realizar uma análise no nível municipal poderia incorrer em um erro ao separar Contagem e Betim de Belo Horizonte, por exemplo.

Restam ainda dois níveis atuais de agregação do IBGE: regiões geográficas imediatas (microrregional) e regiões geográficas intermediárias (mesorregional). Seguindo a argumentação de Araújo (2014) para o caso da inovação no âmbito regional, a existência de uma integração econômica interna ao nível regional e um fluxo estável de trabalhadores dentro dessas áreas recomenda o uso das regiões geográficas imediatas (microrregião).

Essa opção parece adequada do ponto de vista da avaliação de estrutura produtiva local, como apontaram os resultados de Beaudry & Schiffauerova (2009). Ainda que seja difícil definir a priori um nível geográfico para análise, os autores comparam diferentes resultados de trabalhos sobre o desempenho das regiões especializadas e diversificadas de acordo com o nível geográfico. No que diz respeito aos níveis de agregação espacial, os autores indicam que medidas muito desagregadas ou muito estritas podem superestimar ou subestimar o papel da especialização ou diversificação produtiva, por isso sugerindo a adoção de níveis intermediários, que englobem um mesmo mercado de trabalho, o que reforça a escolha do nível microrregional.

Entretanto, segundo Araújo (2014), as microrregiões estão longe de ser homogêneas e apresentam enorme disparidade de dimensões. Por esse motivo, além de estimar o modelo para as regiões geográficas imediatas (microrregiões), são realizadas também análises de heterogeneidade espacial com o propósito de mitigar as expressivas heterogeneidades da dinâmica industrial entre as regiões imediatas do país e reduzir possíveis problemas oriundos da falta de homogeneidade espacial, além de potenciais problemas de MAUP.

O período inicial foi escolhido devido às alterações da Classificação Nacional de Atividade Econômica (CNAE) 1.0 - CNAE-Fiscal 1.1 (Resolução Concla nº 07 de 16/12/2002) -, que vigorou a partir de abril de 2003, de forma sincronizada com a atualização dos demais níveis da tabela na CNAE 1.0 para os dados de emprego formal da Relação Anual de Informações Sociais (RAIS). O período final escolhido se ateve em não modelar o choque exógeno da COVID-19 que ocorreu nos meados de 2020. A base de dados refere-se às habilidades das ocupações formais da indústria de transformação privada.

O indicador extraído considera o número de ocupações formais da indústria de transformação da RAIS (CNAE 2.0, Div.10 a 33) para o setor privado (Natureza jurídica: não pública). Para

as estimações da heterogeneidade industrial, a indústria foi dividida em 2 grupos: 1) agroindústria e não agroindustrial (Apêndice B – Tabela B.1) e 2) Indústria intensiva em capital e indústria intensiva em trabalho (Apêndice B – Tabela B.2). Fez-se o *matching* entre a CBO das ocupações e a nota de 0 a 1 para as habilidades cognitivas, sociais e motoras, com base em Maciente (2013) e Neves, Azzoni & Chagas (2021), calculando-se média, mediana e média do último quartil das habilidades para cada RGI¹⁹. A comparação da média com a mediana fornece uma medida da assimetria da distribuição das notas de habilidades. Em particular, uma média superior à mediana representa que os valores no topo da distribuição estão muito distantes da base da distribuição. A utilização da média do último quartil das habilidades possibilita comparar a média das 25% maiores notas de habilidades de cada RGI permitindo identificar habilidades que são extremamente altas na indústria e que estão distantes da maioria das notas de habilidades, propiciando um quadro comparativo das distribuições das habilidades em conjunto com a média e mediana.

Esses indicadores de cada trabalhador são utilizados nesta análise. Em cada região, somam-se os indicadores de habilidades de todos os seus trabalhadores, gerando-se um indicador da média, mediana e médias os quartis de habilidades da indústria utilizadas na região. Portanto, a indústria de cada região tem três indicadores por ano, sendo um para habilidades cognitivas e os outros para habilidades sociais e motoras. Foram gerados indicadores anuais para o período 2003-2019, permitindo-se compor um quadro comparativo de grande interesse. O passo seguinte é calcular a taxa de crescimento das habilidades para cada RGI. Os níveis e suas respectivas taxas de crescimento são calculados para a média geral, mediana e média do último quartil.

Por fim, foi também utilizada a escolaridade média dos trabalhadores formais da indústria. Para o cálculo foi utilizada a tabela de ano de estudo por grau de instrução (Apêndice C – Tabela C.1). O indicador é extraído da seguinte forma: i) número de ocupações formais da indústria de transformação da RAIS (CNAE 2.0, Div.10 a 33) para o setor privado (Natureza jurídica: não pública; ii) *matching* entre o grau de instrução e a tabela de ano de estudos, com base em Bernardelli et al (2020) e Castro, Barros & Menezes (2021) (Apêndice C – Tabela C.1); iii) cálculo da média para cada RGI.

¹⁹ Estratégia semelhante foi utilizada em Castro & Azzoni (2022).

Com a adoção desses cortes, toda a base de dados constitui um painel desbalanceado, pois há regiões, principalmente no Norte do país, em que não há informações para a indústria em todos os anos. Dessa forma, decidiu-se eliminar essas RGI para constituir um painel balanceado de 492 RGI, cerca de 96,5% do total das RGI, em que há informações disponíveis em todos os anos do estudo (2003-2019). Embora o número de RGI tenha se reduzido em 3,6%, o número de emprego se reduziu em apenas 0,004% e 0,023% em 2003 e 2019, respectivamente, pois as RGI eliminadas possuem baixa participação no emprego industrial. Portanto, a eliminação dessas RGI não tem impacto significativo na amostra desta tese.

3.9 FLUXOGRAMA METODOLÓGICO

Esta seção tem o propósito de sintetizar os procedimentos metodológicos utilizados nesta tese. A princípio, esse resumo (Figura 13) serve tanto para os modelos de convergência condicional global, representados pelas equações (7), (8) e (9), quanto para os modelos de convergência condicional por clusters, representados pelas equações (13), (14) e (15). Cabe destacar que a principal diferença entre os dois modelos em termos de especificação é que, para o primeiro modelo, há apenas um parâmetro β que representa a convergência de todas as RGI (convergência global), enquanto para o segundo modelo há mais de um parâmetro β , que representa a convergência das RGI por classe de tamanho e sua interpretação é sempre em relação ao β do cluster de referência, devido à *dummy* multiplicativa.

Dito isto, o procedimento de estimação se inicia com a regressão OLS com efeito fixo de RGI e tempo. O próximo passo é analisar se há ou não autocorrelação espacial nos resíduos, decorrente das características não observáveis que são autocorrelacionadas espacialmente, e verificar se há ou não dependência espacial na variável dependente, por meio dos testes de Multiplicador de Lagrange e Multiplicador de Lagrange Robustos (Anselin, 1988; Anselin et al., 1996; Fischer & Wang, 2011)²⁰. Como descrito nas seções anteriores, na presença de autocorrelação espacial nos resíduos, o β -convergência fica viesado. Caso não haja autocorrelação espacial nos resíduos, o β e o intervalo de confiança são apresentados na forma de gráfico. Por outro lado, se houver presença de autocorrelação espacial nos resíduos, o

²⁰ Em teoria, é necessário corrigir as probabilidades em testes sequenciais. Na prática, embora sejam utilizados pré-testes (LMI, RLMI, LMe, RLMe), não foi feita correção das probabilidades nos testes subsequentes. Porém, mesmo sem realizar tal correção, como os valores-p dos testes apresentados adiante são próximos de zero, é pouco provável que haja mudanças nas escolhas dos modelos ao utilizar, por exemplo, a correção de Bonferroni. Portanto, os resultados não se alterariam mesmo que as probabilidades dos testes fossem corrigidas.

próximo passo é utilizar a abordagem proposta por LeSage & Pace (2009) e Elhorst (2010), implementando a abordagem geral (mais complexa) dos modelos espaciais para as estimativas das equações de convergência por meio do modelo SDM.²¹

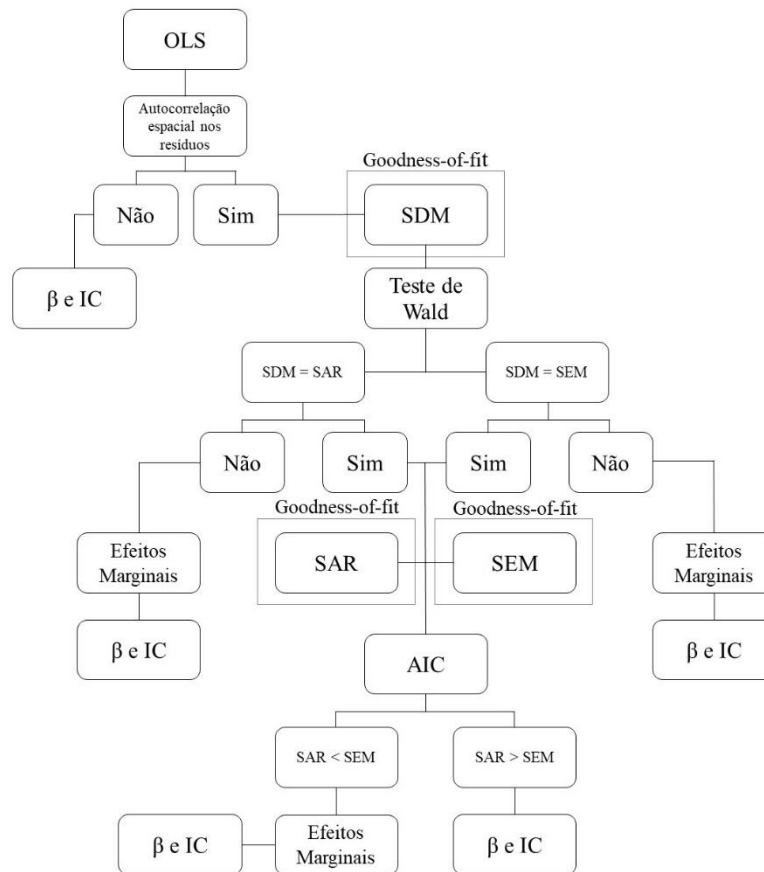
Para a estimação do modelo SDM é definida a matriz de pesos espaciais com base no critério de “*goodness-of-fit*”, sendo estimados 30 modelos com a matriz de vizinhança *k-nearest neighbors* variando de 1 a 30. O modelo que possui o menor critério de informação AIC dentre os 30 tem a maior probabilidade de conter a matriz de vizinhança correta e é o modelo analisado. Com o modelo SDM e com a matriz de vizinhança correta em mãos, é realizado o teste de Wald (teste de restrição de parâmetros) para verificar se uma abordagem menos complexa, por meio dos modelos SAR e SEM, é preferível a uma abordagem mais complexa das relações espaciais (modelo SDM).

Para este caso, existem cinco possibilidades: i) o modelo SDM ser diferente do modelo SAR, caso em que o modelo SDM é preferível; ii) o modelo SDM ser igual ao modelo SAR, então o modelo SAR é preferível; iii) o modelo SDM ser igual ao modelo SEM, então o modelo SEM é preferível; iv) os modelos SAR e SEM serem preferíveis ao modelo SDM, caso em que o modelo com o melhor critério de informação AIC é escolhido; v) o modelo SDM ser diferente do modelo SEM, então o modelo SDM é preferível.

Se o modelo SDM for diferente do modelo SAR, isso implica que, ao inserir a defasagem espacial da variável explicativa juntamente com a defasagem espacial da variável explicada, além de corrigir a dependência espacial nas perturbações do modelo OLS, também trata-se a existência de uma variável explicativa omitida que apresenta covariância diferente de zero com uma variável incluída no modelo (Fischer & Wang, 2011). Variáveis omitidas são prováveis quando se trata de amostras de dados espaciais (LeSage & Fischer, 2008). Em outras palavras, a dependência espacial capturada pela defasagem da variável explicada (ρ) não é suficiente para explicar os dados. Essa constatação se deve à suspeita de que as relações espaciais são mais complexas do que aquelas abordadas apenas pela dependência espacial do parâmetro ρ . Portanto, as análises devem prosseguir com o cálculo dos efeitos marginais (diretos, indiretos e totais) e o β do efeito total e o intervalo de confiança são apresentados na forma de uma figura.

²¹ Abordagem denominada “general-to-specific” de Hendry (2000).

Figura 13: Fluxograma metodológico



Fonte: elaborado pelo autor (2023).

A segunda possibilidade ocorre quando não há diferença estatística entre o modelo SDM e o modelo SAR. Nesse caso, a dependência espacial capturada pela defasagem da variável explicada (ρ) é suficiente para explicar os dados, ou seja, as relações espaciais não são tão complexas quanto as abordadas pelo modelo SDM. Portanto, as análises prosseguem com a estimação do modelo SAR com a matriz de pesos espaciais definida pelo critério “*goodness-of-fit*”. Em seguida, são calculados os efeitos marginais (diretos, indiretos e totais) e o β do efeito total e o intervalo de confiança são apresentados na forma de uma figura.

A terceira possibilidade ocorre quando o modelo SDM é igual ao modelo SEM caso em que o modelo SEM é preferível. Assim, o foco principal está na autocorrelação espacial nos erros, ou seja, a estrutura dos resíduos é o aspecto mais importante a ser modelado. Portanto, as análises seguem com a estimação do modelo SEM com a matriz de pesos espaciais definida pelo critério “*goodness-of-fit*” e o β do efeito total e o intervalo de confiança são apresentados na forma de uma figura.

A quarta possibilidade ocorre quando os modelos com menor complexidade (SAR e SEM) são preferíveis ao modelo SDM. O próximo passo é decidir qual abordagem utilizar. O modelo SAR é preferível ao modelo SEM quando a dependência espacial direta entre as unidades vizinhas é considerada mais importante do que a autocorrelação espacial nos erros. Em outras palavras, acredita-se que os valores observados em uma determinada localização são significativamente influenciados pelas observações nas localizações vizinhas, o que é uma parte importante da relação a ser modelada, tornando o modelo SAR a escolha mais apropriada. Por outro lado, o modelo SEM é preferível ao modelo SAR quando a autocorrelação espacial nos erros é mais importante do que a dependência espacial direta entre unidades vizinhas (Fischer & Wang, 2011). Em outras palavras, acredita-se que os erros nas observações possuem uma estrutura espacial que não pode ser adequadamente explicada apenas pela dependência espacial direta, tornando o modelo SEM uma escolha mais apropriada. No entanto, uma maneira de fazer essa escolha é através do critério de informação AIC, que envolve a comparação dos valores de AIC de ambos os modelos e a seleção daquele com o valor mais baixo, que é considerado mais adequado, uma vez que busca um equilíbrio entre o ajuste do modelo aos dados e a complexidade do modelo (Arbia, Basile & Piras, 2005). Portanto, se o modelo SAR tiver um valor de AIC mais baixo, isso sugere que a dependência espacial direta entre as unidades vizinhas é mais importante para explicar os padrões nos dados. Se o modelo SEM tiver um valor de AIC mais baixo, há indicação de que a autocorrelação espacial nos erros é um fator mais relevante. Em seguida, as análises prosseguem com o cálculo dos efeitos marginais (caso o modelo SAR seja escolhido) e a apresentação do β do efeito total e do intervalo de confiança na forma de uma figura.

A quinta possibilidade é quando o modelo SDM é diferente do modelo SEM, sendo o modelo SDM preferível. Logo, as análises seguem com os cálculos dos efeitos marginais e o β do efeito total e o intervalo de confiança são apresentados na forma de figura.

Há também uma sexta possibilidade, na qual, em um dos casos, o modelo SDM é preferível ao modelo SAR (SEM) mas na outra possibilidade o modelo SEM (SAR) é preferível ao modelo SDM. Para esse caso, sempre será preferida a abordagem menos complexa para capturar as relações espaciais.

Em síntese, a metodologia adotada proporciona uma abordagem abrangente para a análise da convergência condicional das habilidades, considerando a complexidade das relações espaciais

e a preferência por modelos mais simples quando for apropriado, seguindo a literatura de econometria espacial para dados em painel.

4 RESULTADOS E DISCUSSÃO

Este capítulo apresenta os resultados das estimações econométricas realizadas nesta tese. São apresentadas as estimativas de convergência para a média geral, mediana e média do último quartil. Além disso, são apresentados alguns exercícios de robustez e de heterogeneidade setorial e regional, cujos resultados são expostos ao longo do capítulo.

4.1 CARACTERÍSTICAS DA AMOSTRA

As estatísticas descritivas apresentadas nesta seção são baseadas no banco de dados extraído dos microdados da RAIS (2003-2019) usados para a estimação dos resultados desta tese. A descrição detalhada do processo de geração do banco de dados está disponível na seção de metodologia. A Tabela 3 apresenta as estatísticas descritivas das variáveis utilizadas na estimação da equação de convergência

Tabela 3: Estatísticas Descritivas para as habilidades

Tipo	Medida	Min.	1st.	Mediana	Média	3rd	Max.
Média							
Cognitiva	nível	0.1651	0.2817	0.2974	0.2979	0.3133	0.4643
	taxa	0.5298	0.9908	1.0017	1.0016	1.0122	1.5046
Social	nível	0.1185	0.2068	0.2237	0.2243	0.2406	0.3973
	taxa	0.5374	0.9891	0.9986	0.9994	1.0084	1.7166
Motor	nível	0.2512	0.4493	0.4681	0.4676	0.4869	0.6141
	taxa	0.4462	0.9858	1.0020	1.0019	1.0171	1.7598
Mediana							
Cognitiva	nível	0.1029	0.2479	0.2719	0.2723	0.2919	0.5170
	taxa	0.4058	0.9941	1.0000	1.0010	1.0074	1.8966
Social	nível	0.0952	0.1613	0.1843	0.1843	0.2031	0.5332
	taxa	0.1517	0.9983	1.000	1.0015	1.0000	6.1462
Motor	nível	0.0838	0.4837	0.5262	0.5126	0.5475	0.6984
	taxa	0.2360	0.9911	1.0000	1.0030	1.0115	2.9288
Média do último quartil							
Cognitiva	nível	0.3724	0.4720	0.4841	0.4829	0.4951	0.7584
	taxa	0.7320	0.9915	1.0005	1.0010	1.0097	1.7932
Social	nível	0.2961	0.4192	0.4342	0.4370	0.4518	0.6702
	taxa	0.5360	0.9862	1.0013	1.0014	1.0160	1.4671
Motor	nível	0.5762	0.6328	0.6431	0.6428	0.6528	0.9114
	taxa	0.7840	0.9962	1.0004	1.0005	1.0046	1.2512

Fonte: elaborado pelo autor (2023).

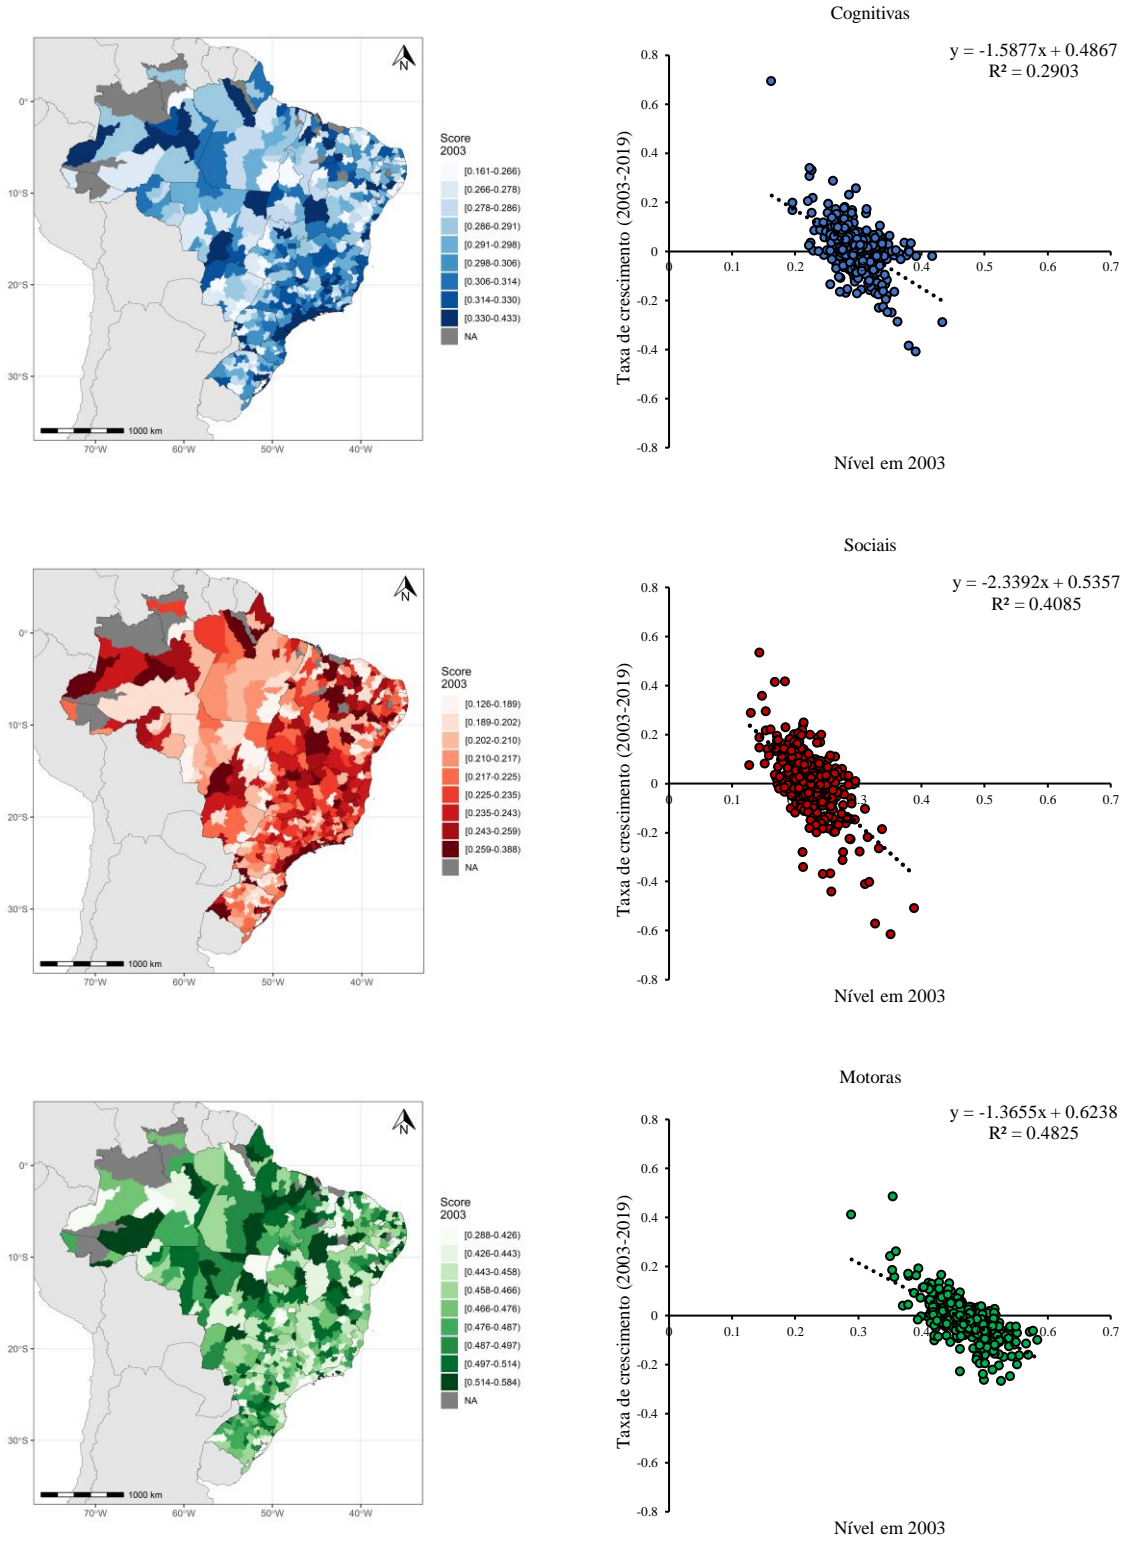
O banco de dados é composto por 492 RGI para cada ano da série (2003-2019), sendo que cada variável no banco de dados possui 8.364 observações. De maneira geral, percebe-se que os níveis são maiores para as habilidades motoras em relação às demais para a média geral, mediana e média do último quartil. As habilidades sociais possuem os menores níveis para as três métricas utilizadas, porém possuem as maiores taxas de crescimento, comparadas com as demais, exceto para a média do último quartil. As habilidades cognitivas se destacam por possuírem os maiores níveis mínimos, exceto para a média do último quartil, e apresentam as maiores taxas de crescimento máximas para a média do último quartil. Uma outra forma de visualizar as estatísticas descritivas está no apêndice D (Tabela D.1, Tabela D.2 e Tabela D.3), em que é possível notar alguns choques comuns à indústria ao longo do tempo, como as crises externas (2008-2009) e internas (2016), também observadas por Azzoni & Castro (2023).

Pela característica da indústria, espera-se que a demanda por mão de obra nesse setor requeira mais trabalhadores com habilidades motoras, comparadas com as demais habilidades. Se essa característica for de fato correta, é de se esperar que as demais habilidades tenham taxas de crescimentos maiores, uma vez que os fatores que são mais escassos (ocupações na indústria com habilidades cognitivas e sociais altas) são os que mais crescem se as condições de Inada prevalecerem²². A Figura 14 apresenta a distribuição espacial das habilidades em 2003 e as suas respectivas taxas de crescimento no período (2003 e 2019). De maneira geral, as regiões tradicionalmente industrializadas (Sudeste, Sul e ZNF de Manaus) estão alocadas nos maiores percentis. Entretanto, regiões pouco industrializadas (Noroeste e Norte da região Norte e interior da região Nordeste) também apresentam notas elevadas das habilidades, indicando que apesar de apresentarem pouca participação no emprego industrial, as ocupações lotadas nessas RGI possuem altos níveis de habilidades, refletindo no indicador de média das habilidades. Essas evidências reforçam a necessidade de analisar as médias do último quartil de habilidades, além do uso dos métodos de econometria espacial e do controle de efeito fixo de região.

As RGI em cinza não apresentam informações para todos os anos. Como destacado no capítulo anterior, ao todo são 18 RGI que representam apenas 0,023% do emprego na indústria.

²² Pressupostos sobre a forma de uma função de produção que garante a estabilidade de uma trajetória de crescimento econômico em um modelo de crescimento neoclássico. Essa afirmação só é verdadeira se as habilidades forem fatores de uma função de produção da sofisticação industrial continuamente diferenciável, tal que $f: X \rightarrow Y$, em que $X = \{x: x \in R_+^n\}$ e $Y = \{y: y \in R_+\}$. Se essa suposição for verdadeira, o limite da primeira derivada é positivo infinito quando x_i tende a zero: $\lim_{x_i \rightarrow 0} \frac{\partial f(x)}{\partial x_i} = +\infty$. Ou seja, quanto mais próximo de zero forem as habilidades, maiores serão suas taxas de variação.

Figura 14: (A) Distribuição espacial de habilidades em 2003 e (B) níveis de habilidades e taxas de crescimento (2003 e 2019)



Fonte: elaborado pelo autor (2023).

A Figura 14 também indica possível convergência de habilidades entre as regiões, com as habilidades sociais convergindo mais rápido e as motoras mais devagar. Percebe-se também que o nível médio em 2003 é maior para as habilidades motoras, seguido das cognitivas e sociais. Esse resultado é semelhante ao apresentado por Castro & Azzoni (2022) para as habilidades de todos os setores privados nas regiões do Estado do Paraná.

A Tabela 4 apresenta as estatísticas descritivas da variável 'escolaridade' (nível e taxa de crescimento) utilizada na estimação da equação de convergência. A média e a mediana da taxa de crescimento da escolaridade são maiores do que as médias e medianas das taxas das habilidades. Esse resultado reflete o aumento na utilização de mão de obra escolarizada na indústria discutida no capítulo 2.2. O apêndice D (Tabela D.4) apresenta outra forma de visualizar as estatísticas descritivas da escolaridade.

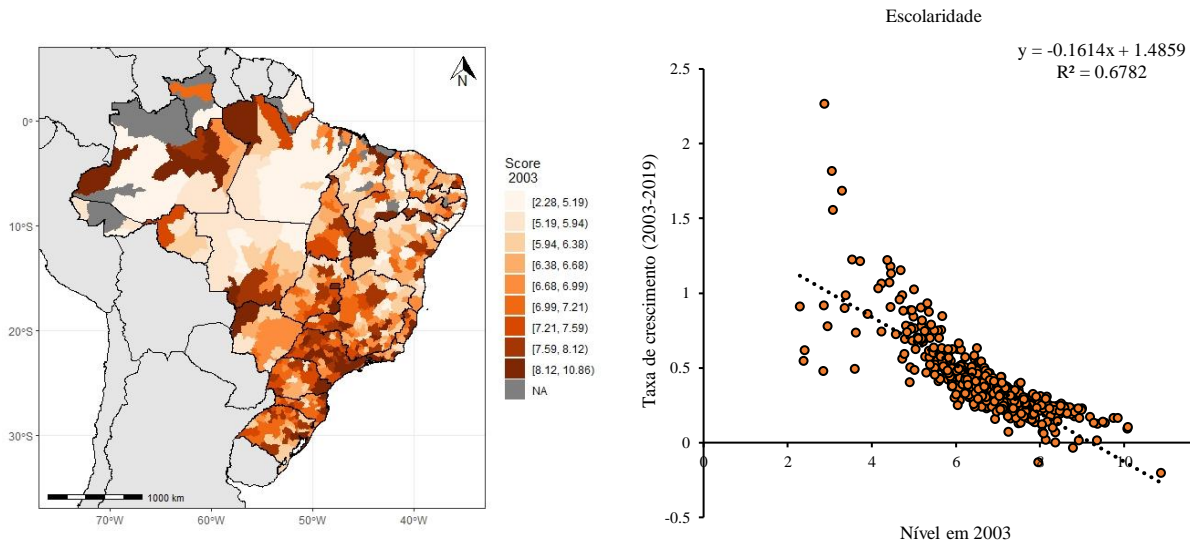
Tabela 4: Estatísticas Descritivas para a escolaridade

Variável	Medida	Min.	1st.	Mediana	Média	3rd	Max.
Escolaridade	nível	2.2880	7.2810	8.218	8.052	8.970	12.210
	taxa	0.4179	1.0043	1.0158	1.0219	1.0328	2.4444

Fonte: elaborado pelo autor (2023).

A Figura 15 apresenta a distribuição espacial da escolaridade em 2003 e suas respectivas taxas de crescimento no período (2003 e 2019). Assim como as habilidades, as regiões tradicionalmente industrializadas (Sudeste, Sul e ZNF de Manaus) estão alocadas nos maiores percentis de escolaridade. Entretanto, regiões pouco industrializadas (Noroeste e Norte da região Norte e interior da região Nordeste) também apresentam notas elevadas de escolaridade. Percebe-se que tanto para a escolaridade quanto para as habilidades cognitivas e sociais, as RGI de Cuiabá – MT e Governador Eduardo Magalhães – BA estão localizadas nos percentis superiores. O fato em comum é que as habilidades e a escolaridade estão convergindo entre 2003 e 2019, como mostram as Figuras 12 e 13. Apesar de ser uma análise *cross-section* e sem controle algum, o parâmetro β -convergência global é -2.34 para as habilidades sociais, -1.59 para cognitivas, -1.36 para motoras e -0,161 para escolaridade.

Figura 15: (A) Distribuição espacial da escolaridade média em 2003 e (B) níveis médios de escolaridade e taxas de crescimento (2003 e 2019)



Fonte: elaborado pelo autor (2023).

A escolaridade pode ter uma influência significativa sobre as habilidades ocupacionais de um indivíduo. Através da educação formal, os indivíduos adquirem conhecimentos, competências e habilidades que são relevantes para uma ampla gama de ocupações. Dentre as maneiras pelas quais a escolaridade pode influenciar as habilidades ocupacionais, destacam-se:

- **Conhecimento específico:** A educação formal proporciona aos indivíduos conhecimentos específicos em áreas como ciências, matemática, línguas, ciências sociais, tecnologia, entre outras. Esses conhecimentos podem ser aplicados em ocupações que exigem competências técnicas e especializadas (Souto-Otero & Bialowolski, 2021).
- **Habilidades cognitivas:** A escolaridade também ajuda a desenvolver habilidades cognitivas, como pensamento crítico, resolução de problemas, habilidades de comunicação e capacidade de aprendizado contínuo. Essas habilidades são relevantes para uma ampla gama de ocupações, independentemente do campo específico (Kautz et al., 2014).
- **Habilidades de pesquisa e análise:** Através da educação, os indivíduos aprendem a realizar pesquisas, coletar dados, analisar informações e tomar decisões com base em evidências. Essas habilidades são valiosas para ocupações que envolvem análise de

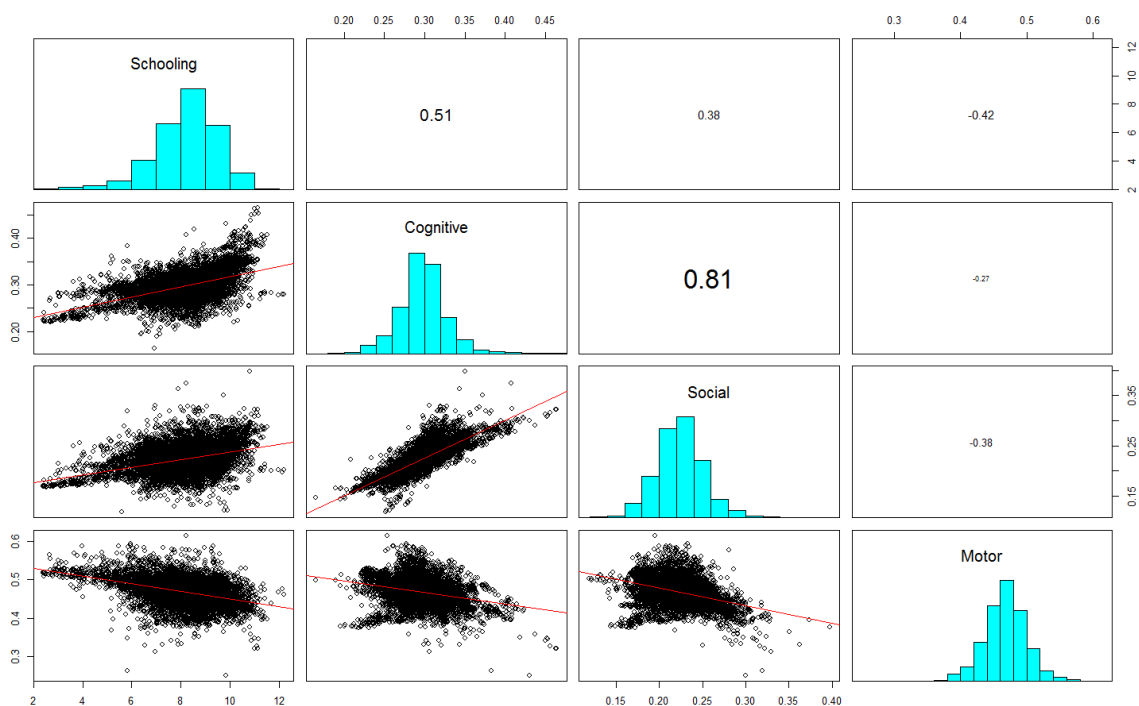
dados, tomada de decisões estratégicas e pesquisa de mercado (Martin, McNally & Kay, 2013; Daniel, 2015).

- **Competências sociais e interpessoais:** A escolaridade também pode contribuir para o desenvolvimento de habilidades sociais e interpessoais, como trabalho em equipe, liderança, empatia e habilidades de comunicação. Essas habilidades são relevantes para ocupações que envolvem interações no ambiente de trabalho, clientes ou o público em geral (Serbim, Stack & Kingdon, 2013; Siddiqui, Gorard & See, 2019).

É importante ressaltar que a influência da escolaridade sobre as habilidades ocupacionais pode variar dependendo do campo de atuação. Algumas ocupações podem exigir níveis mais elevados de educação formal e competências especializadas, enquanto outras podem enfatizar mais a experiência prática ou habilidades específicas não necessariamente adquiridas por meio da escolaridade.

A Figura 16 apresenta evidências de correlação positiva e significativa entre a escolaridade dos trabalhadores da indústria e as habilidades cognitivas (0.51) e sociais (0.38) para toda série (2003 a 2019). Por outro lado, apresentam correlação negativa entre escolaridade e habilidades motoras (-0.42).

Figura 16: Correlação entre escolaridades e habilidades na indústria



Fonte: elaborado pelo autor (2023).

A partir dessas evidências foram calculados indicadores de intensidade de habilidades, multiplicando a escolaridade (em anos de estudo) pelas notas de cada habilidade para cada ocupação da indústria. O indicador final exprime-se em intervalo entre zero (nenhuma habilidade daquele tipo requerida para aquele grau de escolaridade) e um, o grau máximo de escolaridade se a ocupação exigir habilidade (habilidade extrema), para cada dimensão. Assim, cada ocupação (isto é, cada trabalhador efetivamente empregado) recebe três valores entre zero e o grau máximo de escolaridade se a ocupação exigir habilidade extrema, sendo um valor para cada tipo de habilidade. Para este indicador, a escolaridade sofre uma penalidade da habilidade da ocupação. Essa penalidade busca diferenciar trabalhadores que têm o mesmo grau de escolaridade, mas possuem graus de habilidades diferentes e, portanto, diferentes níveis de sofisticação industrial.

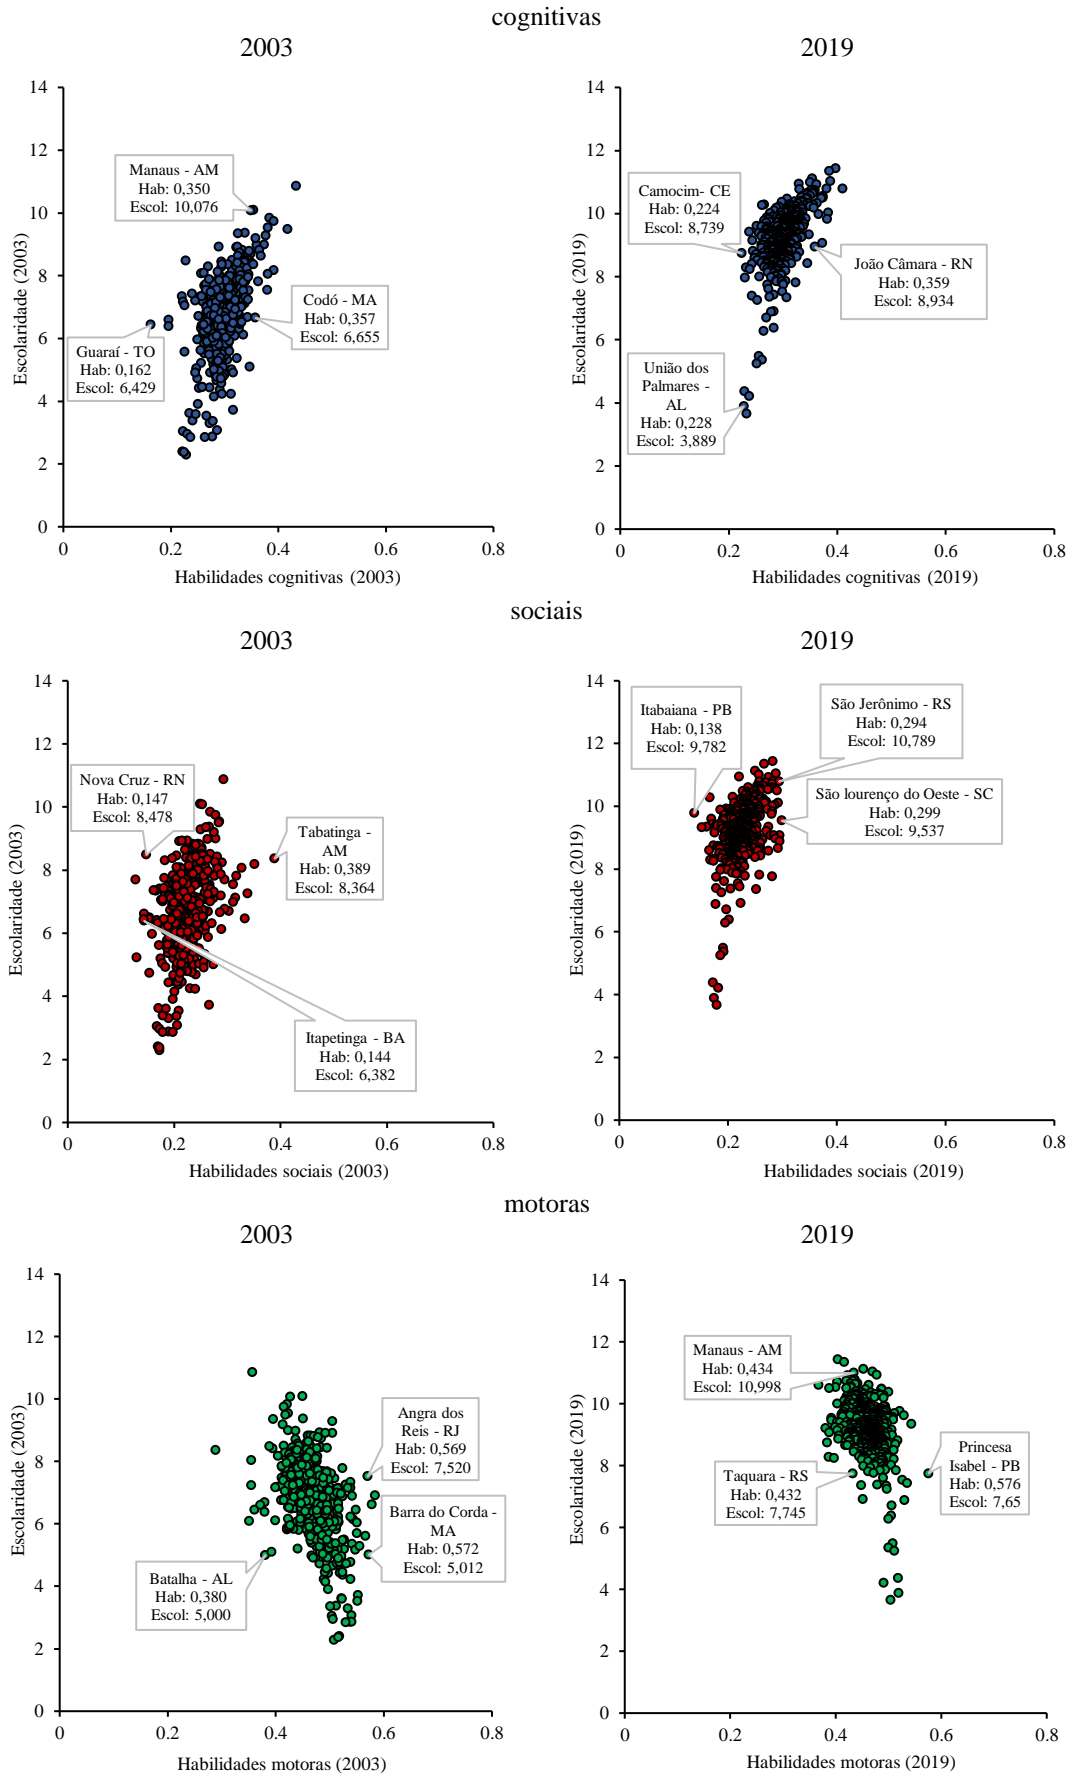
Dessa forma, a indústria de uma região pode ter um conjunto semelhante de ocupações que requerem o mesmo nível de escolaridade que a indústria de outra região, tendo ambas o mesmo nível de capital humano. No entanto, o nível de habilidades exigido pelas ocupações dos seus trabalhadores pode ser diferente, o que afeta a intensidade da sofisticação. Evidentemente, essa diferença pode estar relacionada a questões de mercado de trabalho local e ao tipo de indústria instalada nessas regiões, o que resulta na subutilização do capital humano na indústria.

Por outro lado, a indústria de uma região pode ter um conjunto semelhante de ocupações que requerem as mesmas habilidades que a indústria de outra região, tendo ambas o mesmo grau de sofisticação. Porém, o nível de escolaridade dos seus trabalhadores pode ser diferente, afetando a intensidade da sofisticação. Claramente, o indicador de intensidade está relacionado a ocupações que não exigem graus de instrução mais elevados. Desta forma, pode-se ter um engenheiro pós-graduado trabalhando como motorista de Uber, que exige uma escolaridade mínima como ensino fundamental incompleto²³, mas não se pode ter ensino fundamental incompleto para uma ocupação de engenheiro.

A Figura 17 apresenta a relação entre escolaridades e habilidades na indústria para as 510 RGI nos anos de 2003 e 2019. A comparação entre esses dois anos revela tanto o aumento da escolaridade quanto o aumento das habilidades, conforme destacado na seção 2.2.

²³ O Código de trânsito brasileiro exige que o indivíduo saiba saber ler e escrever para a obtenção da CNH (Carteira Nacional de Trânsito).

Figura 17: Relação entre escolaridades e habilidades na indústria (510, RGI)



Fonte: elaborado pelo autor (2023).

Nota-se que a dispersão se reduziu entre os anos, devido ao aumento da escolaridade. Para fins de análise, foram calculados os desvios-padrão de cada variável. A escolaridade reduziu seu desvio-padrão de 1,27 em 2003 para 0,93 em 2019. As habilidades cognitivas, sociais e motoras reduziram seus desvios-padrão de 0,030, 0,032 e 0,037 em 2003 para 0,027, 0,025 e 0,027 em 2019, respectivamente.

No entanto, a Figura 17 apresenta alguns insights importantes para a análise das intensidades de habilidades, uma vez que existem RGI que possuem níveis semelhantes de escolaridade, mas habilidades distintas, destacando a subutilização do capital humano nessas RGI. Por exemplo, a escolaridade média das ocupações na indústria em Codó, no Maranhão, é semelhante à de Guaraí, no Tocantins, com 6,6 e 6,4 anos de estudos, respectivamente. No entanto, os níveis de habilidades cognitivas são de 0,36 em Codó, e 0,16 em Guaraí. Portanto, apesar de possuírem o mesmo nível de capital humano, a indústria de Codó é mais sofisticada do que a indústria em Guaraí e, conseqüentemente, é mais “intensiva em habilidades”. Por outro lado, a indústria em Manaus possui habilidades cognitivas semelhantes à indústria em Codó - MA. Portanto, essas RGI possuem o mesmo grau de sofisticação. No entanto, a indústria em Manaus é mais “intensiva em habilidades” do que a indústria em Codó, uma vez que a escolaridade média é de 10,08, ou seja, superior ao nível de escolaridade da indústria em Codó.

Com base nas constatações apresentadas, é evidente que a análise das habilidades e da escolaridade, tanto separadamente quanto em conjunto, desempenha um papel fundamental na compreensão da dinâmica do mercado de trabalho. A combinação desses fatores permite uma avaliação mais abrangente da sofisticação em diferentes regiões. Ao calcular os indicadores de intensidade de habilidades, que consideram a interação entre a escolaridade e as habilidades necessárias para cada ocupação, é possível identificar discrepâncias significativas na utilização do capital humano em diversas áreas geográficas.

Regiões com níveis semelhantes de escolaridade podem apresentar diferenças substanciais nas habilidades exigidas para suas ocupações, afetando a sofisticação industrial. Isso destaca a importância de analisar as necessidades específicas do mercado de trabalho local e o tipo de indústria presente nas regiões. Por outro lado, regiões com habilidades semelhantes podem ter diferenças significativas em termos de escolaridade de seus trabalhadores, o que influencia a intensidade da sofisticação.

Essa análise também evidencia que o indicador de intensidade está relacionado a ocupações que não exigem níveis mais elevados de instrução. Portanto, é crucial reconhecer que, em algumas situações, trabalhadores com elevada escolaridade podem estar desempenhando funções que requerem níveis mais baixos de educação, demonstrando a complexidade da relação entre escolaridade e habilidades no mercado de trabalho.

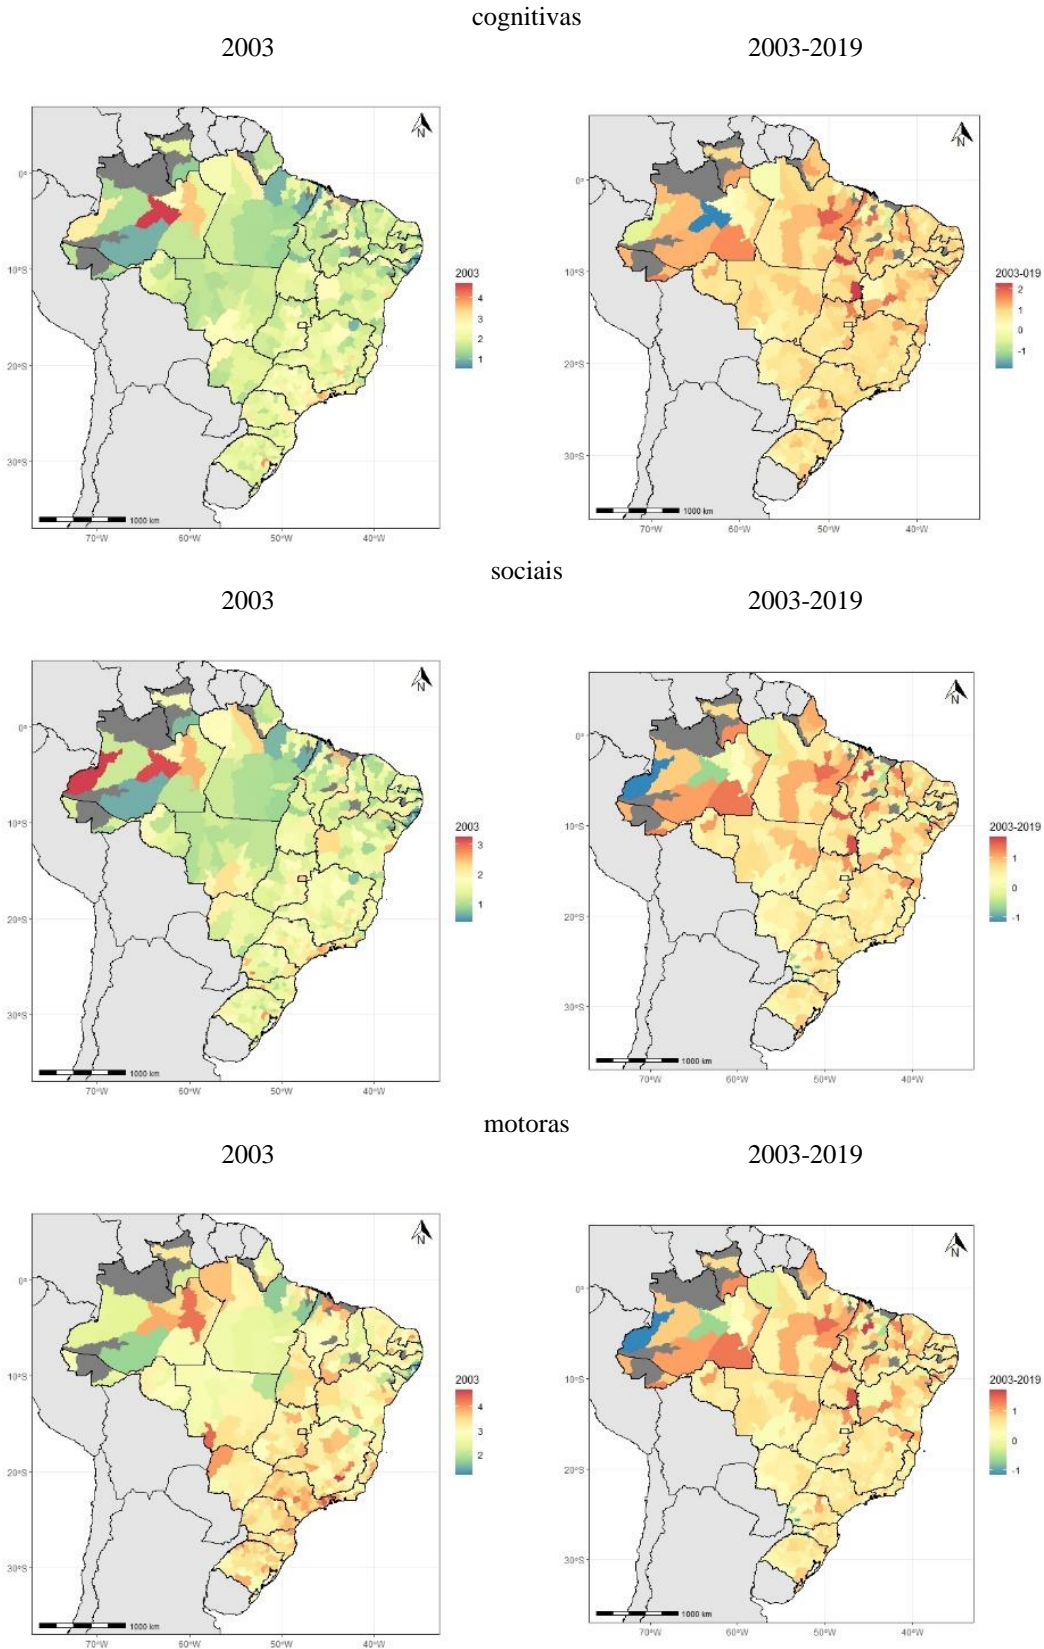
Em resumo, as constatações destacam a importância de avaliar a escolaridade e as habilidades separadamente e em conjunto, a fim de compreender de forma abrangente a dinâmica do mercado de trabalho e a intensidade da sofisticação industrial em diferentes regiões. Isso é essencial para informar políticas e estratégias de desenvolvimento econômico, garantindo uma alocação eficaz do capital humano e a maximização do potencial das indústrias locais.

Dado a importância do indicador de intensidade, a Figura 18 mostra a distribuição espacial da intensidade de habilidade média da indústria nas RGI em 2003 e entre 2003 e 2019. Para todas as habilidades, excluindo as regiões em vermelho, onde a atividade industrial ainda é incipiente, as intensidades se concentram nas regiões tradicionais do Sudeste e Sul para todas as habilidades em 2003. Entre 2003 e 2019 houve variações positivas para a maioria das regiões, com destaque para as RGI do Norte e Nordeste para todas as intensidades de habilidades. As cinco maiores intensidades de habilidades cognitivas em 2003: Charqueada-Triunfo-São Jerônimo – RS, Resende – RJ, São José dos Campos – SP, Santos – SP e Taubaté – SP. Em 2019, os destaques são: São José dos Campos – SP, Charqueada-Triunfo-São Jerônimo – RS, Resende – RJ, Macaé – RJ e Santos – SP.

Para o indicador de intensidade de habilidades sociais em 2003, as RGI que mais se destacaram foram: Dois vizinhos – PR, Santos – SP, Resende – RJ, Charqueada-Triunfo-São Jerônimo – RS e São José dos Campos – SP. Em 2019, tem-se: São José dos Campos – SP, Macaé – RJ, Charqueada-Triunfo-São Jerônimo – RS, Santos – SP e Rio de Janeiro – RJ.

A configuração espacial das intensidades é semelhante à da escolaridade, com destaque para as regiões tradicionalmente industrializadas e para algumas regiões fora do polígono industrial, como Cuiabá – MT e Governador Eduardo Magalhães – BA. Assim como para as habilidades e para a escolaridade, as regiões pouco industrializadas, principalmente ao Norte, apresentaram notas elevadas de intensidades em 2003, indicando que, apesar de apresentarem pouca participação no emprego industrial, suas ocupações possuem altos níveis de habilidades e escolaridade, refletindo no indicador em questão.

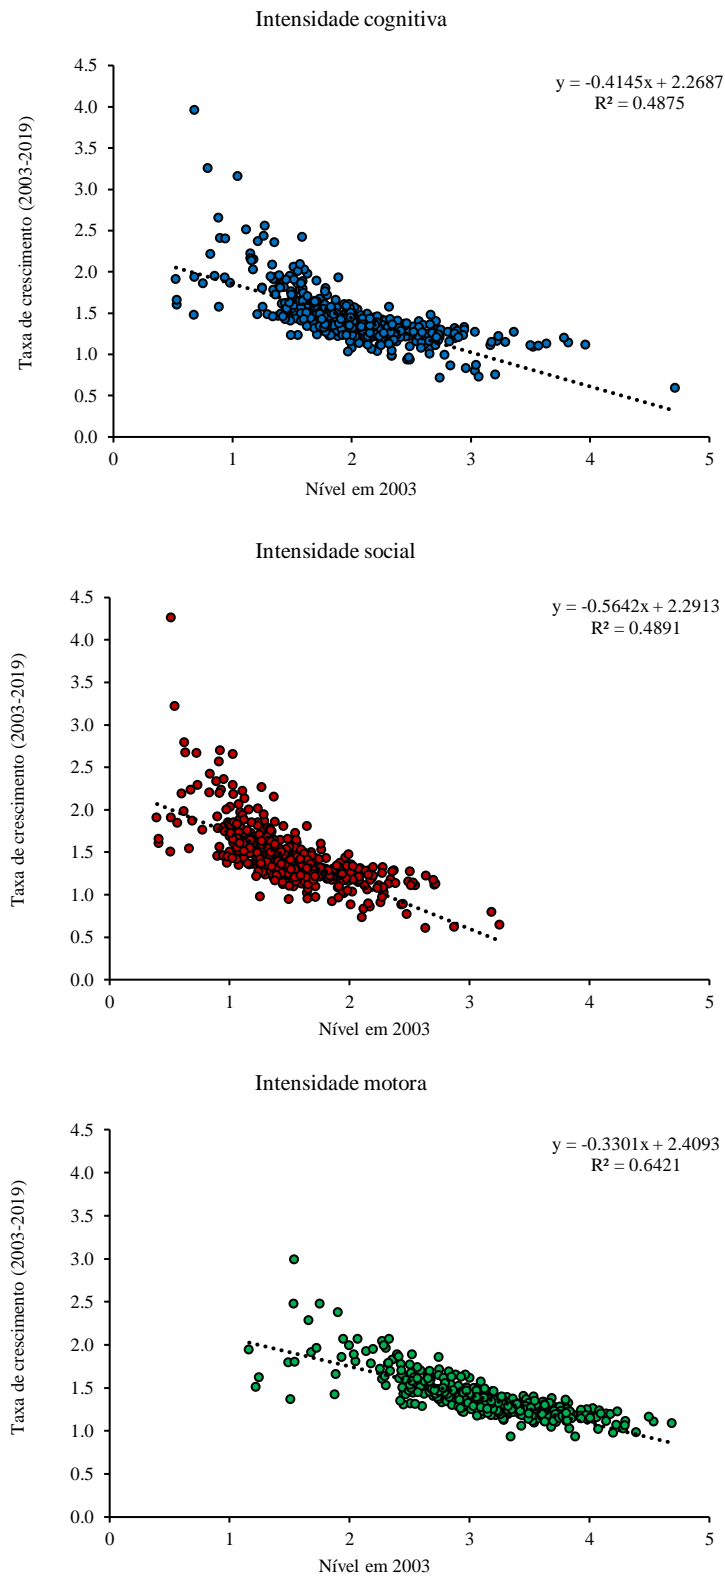
Figura 18: Distribuição espacial da intensidade de habilidades média



Fonte: elaborado pelo autor (2023).

Entre os anos houve variações positivas para a maioria das regiões, com destaque para as RGI do Norte e Nordeste. Por fim, as cinco maiores intensidades de habilidades motoras em 2003 foram: Conselheiro Lafaiete – MG, Taubaté – SP, Cáceres – MT, Cruzeiro – SP e Manaus - AM. Em 2019, foram: Cruzeiro – SP, Botucatu – SP, Macaé – RJ, Conselheiro Lafaiete – MG e Manicoré -AM. De maneira geral, as variações entre 2003 e 2019 ocorreram em direção das RGI com os menores níveis em 2003 para todas as intensidades de habilidades, indicando uma possível convergência, que já foi observada para as habilidades e para a escolaridade.

Com o propósito de verificar possíveis evidências de convergência para as intensidades, a Figura 19 apresenta as taxas de crescimento das intensidades de habilidades no período 2003-2019). A Figura 19 indica uma possível convergência das intensidades entre as regiões no período, replicando a mesma magnitude de convergência das habilidades. O nível médio das intensidades em 2003 é maior para as habilidades motoras, seguido das cognitivas e sociais. De modo geral, as regressões auxiliares apresentadas em conjunto com as figuras para as habilidades, escolaridade e para as intensidades de habilidades apresentam apenas dois recortes no tempo (2003 e 2019) e não possuem nenhum tratamento espacial, controle sobre as características das regiões e sobre os anos da série. Ambos pontos podem alterar os resultados das estimações de convergência. Desta forma, a seção seguinte apresentará os resultados das regressões levando em consideração esses aspectos.

Figura 19: Taxas de crescimento da intensidade de habilidades (2003 e 2019)

Fonte: elaborado pelo autor (2023).

A Tabela 5 apresenta as estatísticas descritivas das variáveis de intensidade (nível e taxa de crescimento) utilizadas nas estimações das equações de convergência, permitindo observar a

distribuição das intensidades em diferentes tipos de medidas. Os valores médios e medianos geralmente estão próximos, o que indica distribuições relativamente simétricas. Além disso, a variação dos valores parece ser mais ampla para a intensidade cognitiva em comparação com social e motora. O apêndice D (Tabela D.5) apresenta uma outra forma de visualizar as estatísticas descritivas da escolaridade.

Tabela 5: Estatísticas Descritivas para a intensidade de habilidades

Tipo	Medida	Min.	1st.	Mediana	Média	3rd	Max.
Cognitiva	nível	0.5236	2.0719	2.4107	2.4162	2.7404	5.1741
	taxa	0.3137	0.9996	1.0183	1.0240	1.0411	2.8388
Social	nível	0.3949	1.5461	1.8031	1.8196	2.0921	4.2949
	taxa	0.2512	0.9957	1.0187	1.0245	1.0457	3.0962
Motor	nível	1.1630	3.4060	3.8150	3.7520	4.1670	5.7680
	taxa	0.5429	1.0008	1.0151	1.0208	1.0341	1.6904

Fonte: elaborado pelo autor (2023).

Há uma diferença notável na média e na mediana das intensidades cognitivas, sociais e motoras. A intensidade motora tende a ter valores médios e medianos mais altos em comparação com as outras duas intensidades. Isso pode indicar uma maior concentração de escolaridade em níveis mais elevados de habilidades motoras, seguido de habilidades cognitivas e sociais.

4.2 CONVERGÊNCIA CONDICIONAL GLOBAL

Essa seção apresenta os resultados da estimação econométrica da equação de convergência condicional global para as habilidades, escolaridade e intensidades. A escolha da matriz espacial pelo critério “*goodness-of-fit*” está disponível no Apêndice E (Tabela E.1, E.8 e E.9). As demais Tabelas do Apêndice E apresentam os resultados completos das estimações dos modelos espaciais, bem como os testes de autocorrelação e dependência espacial, os testes de restrição de parâmetro para a escolha dos modelos espaciais e os resultados dos efeitos marginais. Inicialmente, apresentam-se as estimativas de convergência das habilidades médias, medianas e médias do último quartil; em seguida apresentam-se as estimativas para a escolaridade e para as intensidades de habilidades.

4.2.1 Convergência condicional global das habilidades

A Tabela 6 apresenta os resultados das regressões para a média das habilidades cognitivas. As análises dos resultados seguem o roteiro do fluxograma metodológico apresentado na seção 3.9 do capítulo 3. Inicialmente é apresentada a regressão de convergência condicional global para as habilidades cognitivas por OLS (1), verificando-se se há autocorrelação espacial nos resíduos. As estatísticas dos testes de LMI, RLMI, LMe e RLMe estão apresentadas ao final da segunda coluna da tabela. Os testes confirmam a presença de autocorrelação espacial nos resíduos, indicando que observações próximas umas das outras têm valores mais semelhantes do que seria esperado ao acaso. A detecção da autocorrelação espacial é importante, pois ajuda a identificar padrões geográficos e espaciais que podem influenciar os resultados das análises de convergência das habilidades. Portanto, é necessário incorporar essas relações espaciais na modelagem econométrica.

Tabela 6: Resultado das regressões para a média das habilidades cognitivas

Var.	OLS (1)	SDM (2)	SAR (3)	SEM (4)
β	-0.384*** (0.029)	-0.395*** (0.029)	-0.382*** (0.029)	-0.391*** (0.030)
θ		0.239*** (0.042)		
ρ		0.299*** (0.053)	0.217*** (0.056)	
λ				0.317*** (0.052)
Φ (velocidade implícita)	0.037	0.039	0.037	0.037
MV (meia-vida)	8.083	7.783	8.143	8.029
<i>RGI FE</i>	Sim	Sim	Sim	Sim
<i>Time FE</i>	Sim	Sim	Sim	Sim
Obs.	7872	7872	7872	7872
R2	0.229	0.210	0.189	0.199
LogLik	15910.73	15960.22	15930.78	15951.64
AIC	-31789.46	-31912.05	-31855.56	-31897.27
BIC	-31677.92	-31884.16	-31834.65	-31876.36
LM test, no spatial lag	25.973***			
Robust LM test, no spatial lag	10.611***			
LM test, no spatial error	48.511***			
Robust LM test, no spatial error	33.148***			
	Teste de Wald	Prob>Chi2	Resultado	
	$\theta = 0$ and $\rho \neq 0$	0.0003	SAR \neq SDM	
	$\theta = -\beta\rho$	0.0132	SEM \neq SDM	

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Os possíveis efeitos espaciais de interação, transbordamento ou interdependência foram modelados a partir do modelo SDM. A escolha da matriz espacial se deu pelo critério “*goodness-of-fit*” e está disponível no Apêndice E (Tabela E.1). A matriz espacial que apresentou o menor AIC foi aquela com valor de *knn* igual a 26. Logo, o modelo SDM está apresentado na coluna 3 da Tabela 6. Em seguida, foi realizado o teste de Wald para determinar se a modelagem espacial mais complexa, representada pelo SDM, seria mais adequada em comparação com modelagens menos complexas, como SAR (3) e SEM (4). Esse teste é essencial para avaliar se a complexidade adicional do SDM se traduz em um ajuste estatisticamente superior ou se modelos menos complexos, como SAR e SEM, seriam suficientes para a análise. O teste de hipótese foi aplicado para comparar os parâmetros do modelo SDM com os dos modelos SAR e SEM. Os resultados indicaram que os parâmetros do modelo SDM são estatisticamente diferentes daqueles dos modelos SAR e SEM. Portanto, os parâmetros que foram analisados e considerados para a avaliação derivam especificamente do modelo SDM.

Dado que o modelo selecionado para a análise foi o SDM, observa-se que o parâmetro de defasagem espacial (ρ) demonstrou ser estatisticamente significativo (conforme apresentado na Tabela 6). Tal resultado implica na existência de *spillovers* espaciais da taxa de crescimento por ocupações da indústria com habilidades cognitivas. Em outras palavras, o ρ positivo indica a existência de autocorrelação espacial global positiva.

Em seguida, os efeitos marginais do modelo SDM foram calculados e analisados, considerando o impacto direto, indireto e total do β -convergência condicional global das habilidades cognitivas médias (Tabela 7).

Tabela 7: Efeito direto, indireto e total do modelo SDM para as habilidades cognitivas

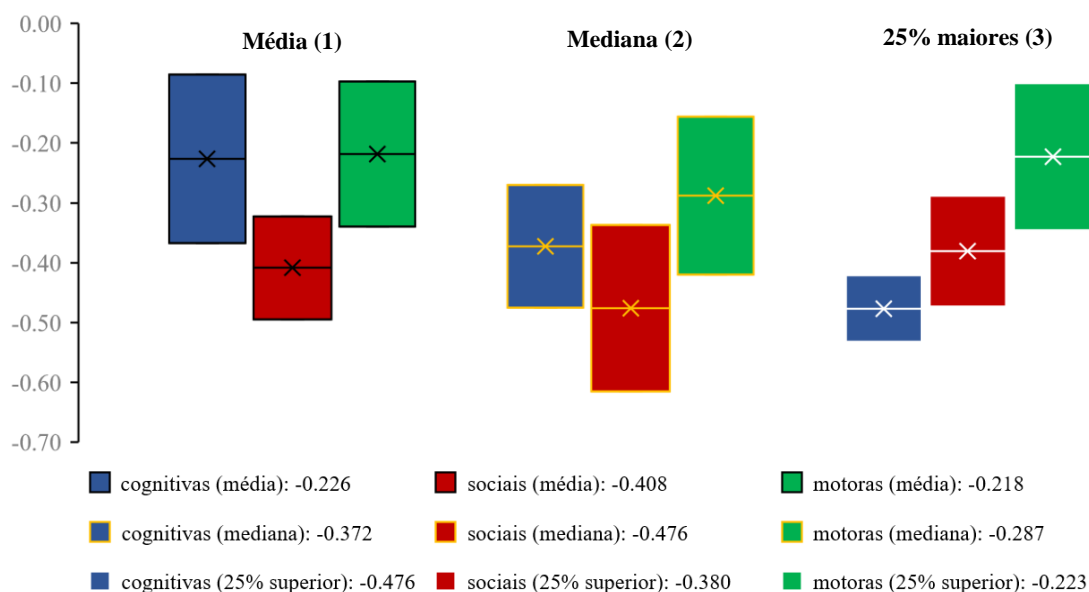
Efeitos	Coefficientes	p-value	Intervalo de confiança	
Direto				
β	-0.392	***	-0.4510095	-0.33443
Indireto				
β	0.016	***	0.0505112	0.282251
Total				
β	-0.266	***	-0.367311	-0.08536

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1.

O efeito total apresenta o valor de -0.226, indicando convergência condicional global das habilidades cognitivas. Esse resultado indica que há uma correlação negativa entre o nível médio inicial das habilidades cognitivas da indústria e sua respectiva taxa de crescimento. Ou seja, regiões com menores níveis médios iniciais de habilidades cognitivas ocupadas na indústria obtiveram as maiores taxas de crescimento. Portanto, as ocupações das indústrias tornaram-se mais semelhantes em habilidades cognitivas.

Com o propósito de facilitar as análises, a Figura 20 apresenta o parâmetro β -convergência das habilidades, seguindo o fluxograma metodológico apresentados na seção 3.9 do capítulo 3. As colunas das figuras representam os parâmetros betas e seus respectivos intervalos de confiança referentes aos modelos econométricos espaciais finais. Evidentemente, se os modelos finais forem o SDM ou SAR, são apresentados os efeitos marginais espaciais totais dos betas e seus respectivos intervalos de confiança. O contorno das colunas representa cada grupo: (1) média (contorno em preto); (2) mediana (contorno em amarelo); e (3) média do último quartil (contorno em branco). O preenchimento das colunas representa cada habilidade: cognitiva (preenchimento em azul); social (preenchimento em vermelho); motora (preenchimento em verde). As colunas preenchidas significam que os parâmetros foram estatisticamente significativos, com p-valor de até 10%. Caso houver, as colunas não preenchidas indicam que o beta não foi estatisticamente significativo. Estes resultados estão nas Tabelas E.2, E.3, E.4, E.5, E.6 e E.7 do Apêndice D.

Figura 20: β -convergência das habilidades na indústria



Fonte: elaborado pelo autor (2023).

As evidências encontradas mostram que há convergência condicional global das habilidades médias, medianas e da média do último quartil. Ou seja, há uma correlação negativa entre as notas iniciais de habilidades e suas respectivas taxas de crescimento. Desta forma, RGI que possuíam níveis menores de habilidades obtiveram maiores taxas de crescimento. Entretanto há diferenças significativas entre os tipos de habilidades e seus grupos. Ao considerar a média de habilidades (contorno em preto), o tamanho do parâmetro beta é maior para as habilidades sociais (-0.41), seguido das habilidades cognitivas (-0.23) e das habilidades motoras (-0.22). Para a mediana das habilidades (contorno em amarelo) o tamanho do parâmetro beta segue o mesmo ordenamento, com as habilidades sociais (-0.48), seguidas das habilidades cognitivas (-0.37) e das habilidades motoras (-0.29). O ordenamento dos parâmetros muda para a média do último quartil (contorno em branco). A convergência é mais intensa para habilidades cognitivas (-0,48), seguidas pelas sociais (-0,38) e motoras (-0,22).

Apesar dos parâmetros serem diferentes, alguns deles parecem estar dentro do mesmo intervalo de confiança, seja entre as habilidades para um mesmo grupo (por exemplo, parâmetro de convergência para as habilidades cognitivas e motoras para as médias) ou entre grupos para uma mesma habilidade (parâmetro de convergência para as habilidades motoras para o grupo de média e média do último quartil). Esses resultados sugerem que pode não haver diferenças estatisticamente significativas entre os betas globais das habilidades para algum dos casos. Para verificar se há diferenças entre os parâmetros utilizou-se o teste *t* pareado (*paired t-test*), também conhecido como *t-test* para amostras dependentes. Este teste é apropriado quando se está comparando duas medidas emparelhadas ou relacionadas, em que cada par de observações nas duas medidas corresponde a uma mesma unidade ou indivíduo.

Os resultados da Tabela 8 indicam que há diferenças entre os parâmetros de convergência intragrupos e intergrupos. Para as análises intragrupos, para o grupo 1 (Média - contorno em preto), para a comparação entre habilidades cognitivas vs. sociais rejeita-se a hipótese nula de que os parâmetros são iguais. O resultado é o mesmo para a diferença entre habilidades motoras vs. sociais. Entretanto, não se rejeita a hipótese nula para os parâmetros das habilidades cognitivas vs. motoras, ou seja, não há diferenças estatisticamente significativas entre os parâmetros das duas habilidades.

Tabela 8: Teste t para a convergência global das habilidades

$H_0: \beta_1 - \beta_2 = 0$			
$H_1: \beta_1 - \beta_2 \neq 0$			
$t_* \pm 1.96$			
	Média		
	cognitivas vs. sociais	cognitivas vs. motoras	motoras vs. sociais
t_0	2.55	-0.11	3.09
	Mediana		
	cognitivas vs. sociais	cognitivas vs. motoras	motoras vs. sociais
t_0	2.00	-1.64	2.83
	Média do último quartil		
	cognitivas vs. sociais	cognitivas vs. motoras	motoras vs. sociais
t_0	-3.48	-9.21	2.52
	Média vs. Mediana		
	cognitivas	sociais	motoras
t_0	2.05	1.56	1.01
	Média vs. Média do último quartil		
	cognitivas	sociais	motoras
t_0	3.49	-0.65	0.08
	Mediana vs. Média do último quartil		
	cognitivas	sociais	motoras
t_0	1.99	-1.36	-0.97

Fonte: elaborado pelo autor (2023).

Para o grupo 2 (Mediana – contorno em amarelo) rejeita-se a hipótese nula de que os parâmetros de convergência condicional das habilidades para a mediana são iguais entre cognitivas vs. sociais e motoras vs. sociais. Entretanto, não se rejeita a hipótese nula para os parâmetros entre cognitivas vs. motoras. No grupo 3 (Média do último quartil – contorno em branco) rejeita-se a hipótese nula de que os parâmetros de convergência condicional para a média do último quartil são iguais entre cognitivas vs. sociais, cognitivas vs. motoras e motoras vs. sociais. Ou seja, todos os parâmetros para esses grupos são diferentes estatisticamente.

A análise intergrupos compara os parâmetros das regressões entre as habilidades do grupo da Média e Mediana. Os parâmetros de convergência das habilidades cognitivas são estatisticamente diferentes para as análises de média (1) e mediana (2). Não se rejeita a hipótese nula para as demais habilidades, ou seja, os parâmetros estimados não são estatisticamente diferentes. Entre os parâmetros dos grupos da Média e a Média do último quartil e Mediana e Média do último quartil, os parâmetros das habilidades cognitivas são estatisticamente diferentes para ambas comparações. As demais não foram estatisticamente diferentes.

Como a hipótese de convergência condicional global foi confirmada, foi realizado o cálculo da velocidade e da meia-vida para as habilidades para os parâmetros betas finais. A velocidade

anual implícita de convergência é uma medida que está relacionada à taxa na qual as diferenças entre as RGI diminuem ao longo do tempo – representada por φ . É uma medida da rapidez com que as unidades geográficas estão convergindo para um estado de equilíbrio. Já a meia-vida indica qual é o tempo necessário para que caia pela metade a diferença de habilidades entre as RGI – representado por MV.

Tabela 9: Velocidade anual implícita de convergência (φ) e Meia-Vida (anos) para as habilidades

Modelos	Cognitivas		Sociais		Motoras	
	φ	Meia-Vida	φ	Meia-Vida	φ	Meia-Vida
Média	0.020	15.250	0.040	7.452	0.019	15.880
Mediana	0.036	8.390	0.050	6.053	0.026	11.523
Média do último quartil	0.050	6.046	0.037	8.179	0.019	15.496

Fonte: elaborado pelo autor (2023).

Os resultados da Tabela 9 indicam que a velocidade implícita da convergência para a média geral e para mediana é maior para as habilidades sociais (0.040) e (0.050), respectivamente. Já a velocidade média para a média do último quartil foi maior para as habilidades cognitivas (0.050). Em relação à meia-vida, o ordenamento é o mesmo, com destaque para o tempo necessário para que se reduza pela metade a diferença entre a média geral das habilidades sociais de 7.4 anos, 15.2 anos para as cognitivas e 15.8 anos para as motoras. A meia-vida para a mediana segue o mesmo ordenamento anterior. Por fim, o indicador de meia-vida para a média do último quartil traz informações interessantes, apresentando que o tempo reduziu para as habilidades cognitivas (6.04 anos) e aumentou para as habilidades sociais (8.1 anos). Cabe destacar que as variáveis truncadas entre 0 e 1, como os indicadores de habilidades, geralmente têm interpretações relacionadas a proporções, taxas de crescimento ou outras medidas que representam mudanças relativas. Quando essas variáveis são usadas em um modelo de convergência espacial, podem resultar em estimativas de convergência mais rápidas porque os coeficientes estão medindo a taxa de mudança em relação a uma escala limitada. Isso pode fazer com que as estimativas de velocidade implícita e meia-vida sejam maiores em comparação com variáveis não truncadas, como PIB per capita, escolaridade e etc.

Embora as indústrias estejam se desconcentrando espacialmente e se apresentem algumas heterogeneidades, como apontado em Saboia (2013), Sobrinho & Azzoni (2016), Silva e Diniz (2020) e Diniz & Mendes (2021), o nível de habilidades da indústria também segue um processo heterogêneo. Os resultados mostram que as habilidades dos trabalhadores da indústria estão

convergindo, ou seja, as regiões que possuíam baixos níveis de habilidades estão obtendo maiores taxas de crescimento. As evidências indicam que, apesar das habilidades dos trabalhadores nas indústrias estarem convergindo, há diferenças significativas entre as magnitudes dos parâmetros e, conseqüentemente, suas velocidades e a meias-vidas. Para a média geral e a mediana, o destaque é para as habilidades sociais; para a média do último quartil, o destaque é para as habilidades cognitivas.

Há de se ressaltar que a convergência é mais lenta para as habilidades motoras em relação às demais. A justificativa pra essa evidência pode estar relacionada aos pontos levantados no capítulo 2 sobre a automatização, avanço tecnológico, aumento da complexidade das tarefas e ao aumento da dependência estrutural da indústria por bens para consumo intermediário e finais importados (terceirização e globalização). Conforme nota de rodapé nº. 18, outra justificativa pode estar relacionada à própria função de produção da sofisticação industrial. De acordo com as condições de Inada, tem-se que quanto mais altas as habilidades, menor será a taxa de variação²⁴.

Do ponto de vista econométrico e espacial, há um efeito de transbordamento espacial intenso, indicando que a taxa média de crescimento das habilidades dos trabalhadores na indústria de uma determinada região é positivamente afetada pela taxa média de crescimento das habilidades da indústria das regiões vizinhas. Portanto, o ambiente geográfico desempenha um papel importante no estudo dos processos de crescimento das habilidades industriais regionais, assim como evidenciando por Ertur, Le Gallo & Baumont, (2006) no processo de crescimento econômico regional.

4.2.2 Convergência condicional global da escolaridade

Argumenta-se nesta tese que quanto mais sofisticadas as ocupações dos trabalhadores de uma região, mais competitivas tendem ser as firmas nela localizadas. Essa sofisticação pode ou não estar relacionada com o grau de instrução dos trabalhadores, uma vez que a escolaridade média (anos de estudo) representa o estoque de capital humano dos trabalhadores ocupados na

²⁴ Como apresentado em nota de rodapé na seção 4.1. Essa afirmação só é verdadeira se as habilidades forem fatores de uma função de produção da sofisticação industrial continuamente diferenciável, tal que $f: X \rightarrow Y$, em que $X = \{x: x \in R_+^n\}$ e $Y = \{y: y \in R_+\}$. Se essa suposição for verdadeira, o limite da primeira derivada é igual a zero quando x_i tende ao infinito: $\lim_{x_i \rightarrow +\infty} \frac{\partial f(x)}{\partial x_i} = 0$. Em outras palavras, à medida que as habilidades aumentam, a taxa de variação diminui.

indústria nessas RGI, mas as indústrias ali presentes podem ou não utilizar trabalhadores em ocupações que requerem habilidades sofisticadas e essas diferenças podem repercutir sobre as análises de convergência.

O objetivo desta análise é verificar se a convergência condicional global das habilidades entre as regiões se deve à escolaridade dos trabalhadores empregados. Os trabalhadores de uma região podem estar aumentando sua escolaridade, passando do ensino médio para o ensino superior, por exemplo, porém as ocupações das indústrias localizadas ali não se alteraram, requerendo os mesmos níveis de habilidades cognitivas, sociais e motoras. Por outro lado, a falta de escolaridade pode restringir as contratações em ocupações com habilidades maiores. Com o propósito de investigar essa relação, a Tabela 10 apresenta a estimação da equação de convergência condicional global para níveis de escolaridade.

Tabela 10: Resultado das regressões para a escolaridade

Var.	OLS (1)	SDM (2)	SAR (3)	SEM (4)
β	-0.318*** (0.038)	-0.359*** (0.043)	-0.314*** (0.038)	-0.344*** (0.042)
θ		0.269*** (0.041)		
ρ		0.361*** (0.046)	0.260*** (0.047)	
λ				0.372*** (0.042)
Φ (velocidade implícita)	0.029	0.034	0.029	0.032
MV (meia-vida)	10.225	8.806	10.395	9.290
<i>RGI FE</i>	sim	sim	sim	sim
<i>Time FE</i>	sim	sim	sim	sim
Observations	7872	7872	7872	7872
R2	0.211	0.193	0.094	0.119
LogLik	13025.29	13190.64	-13092.00	13161.67
AIC	-26018.58	-26373.27	-26177.99	-26317.34
BIC	-25907.04	-26345.39	-26157.08	-26296.42
LM test, no spatial lag	78.362***			
Robust LM test, no spatial lag	92.561***			
LM test, no spatial error	189.79***			
Robust LM test, no spatial error	203.99***			
Teste de Wald		Prob>Chi2		Resultado
$\theta = 0$ e $\rho \neq 0$		0.0000		SAR \neq SDM
$\theta = -\lambda \beta$		0.0000		SEM \neq SDM

Fonte: elaborado pelo autor (2023). Nota: nível de significância ***<0.01; **<0.05 e *<0.1. Erro Padrão Robusto.

Seguindo o fluxograma metodológico, os resultados apresentados na Tabela 10 mostram que o modelo OLS (1) sem os controles espaciais possui autocorrelação espacial nos resíduos. Partindo da abordagem geral por meio do modelo SDM, a matriz espacial que apresentou o

menor AIC foi aquela com valor de knn igual a 15²⁵. O teste de Wald mostra que os parâmetros espaciais do modelo SDM (2) são diferentes aos modelos SAR (3) e SEM (4). As estimações do modelo mostram que há convergência condicional global da escolaridade dos trabalhadores e que há efeito *spillover* sobre as RGI, evidenciado pelo parâmetro ρ . Entretanto, é necessário olhar para os efeitos totais do β -convergência (Tabela 10).

Os efeitos marginais do modelo SDM foram calculados e analisados, considerando o impacto direto e indireto e total do β -convergência condicional global da escolaridade (Tabela 11). O efeito total apresenta o valor de -0.142, indicando convergência condicional global da escolaridade. Esse resultando indica que há uma correlação negativa entre o nível médio da escolaridade da indústria e sua respectiva taxa de crescimento. Ou seja, regiões com menores níveis médios de escolaridade na indústria obtiveram as maiores taxas de crescimento escolaridade na indústria no período de 2003 a 2019. Portanto, a escolaridade média das ocupações dos trabalhadores da indústria está se tornando mais semelhante.

Tabela 11: Efeito direto, indireto e total da regressão espacial para escolaridade

Efeitos	Coefficientes	p-value	Intervalo de confiança	
Direto				
β	-0.35356	***	-0.4405821	-0.2665473
Indireto				
β	0.210753	***	0.1176935	0.3038123
Total				
β	-0.14281	***	-0.2353994	-0.0502242

Fonte: elaborado pelo autor (2023). Nota: nível de significância ***<0.01; **<0.05 e *<0.1.

A Tabela 12 apresenta que há convergência condicional global da escolaridade, com o parâmetro β -convergência total estimado em -0.142, com velocidade implícita de 0.012 e índice meia-vida de 25.39 anos (Tabela 12).

Tabela 12: Velocidade anual implícita de convergência (φ) e Meia-Vida (anos) para a escolaridade

Modelo	φ	Meia-Vida
Escolaridade	0.012	25.395

Fonte: elaborado pelo autor (2023).

²⁵ A escolha da matriz espacial se deu pelo critério “*goodness-of-fit*” e está disponível no Apêndice E (Tabela E.8).

As evidências desta seção indicam que a escolaridade na indústria também está convergindo entre as RGI, assim como as habilidades, porém com menor velocidade. Dependendo da indústria em cada região, pode haver ênfase maior na aquisição de habilidades em vez de educação formal. Isso pode fazer com que as habilidades se ajustem mais rapidamente às necessidades do mercado de trabalho em comparação com a escolaridade. Por outro lado, a estrutura da indústria em diferentes regiões pode influenciar o ritmo de mudança na escolaridade. Por exemplo, indústrias que dependem mais de trabalhadores altamente escolarizados podem ter uma convergência mais lenta do que aquelas que dependem mais de habilidades menos sofisticadas. Esses são apenas alguns dos fatores que podem explicar por que a escolaridade está convergindo a uma velocidade mais lenta do que as habilidades. A análise completa do fenômeno exigiria uma investigação mais aprofundada das condições específicas em cada região e setor industrial (alguns pontos serão explorados nesta tese).

De qualquer forma, os resultados corroboram os dados apresentados na seção 2.2, nos quais tanto a oferta quanto a demanda por trabalhadores escolarizados têm aumentado no Brasil nas últimas décadas. Desta forma, as análises de convergência mostram que os trabalhadores das indústrias nas RGI estão se tornando mais semelhantes em termos educacionais.

4.2.3 Convergência condicional global da intensidade das habilidades

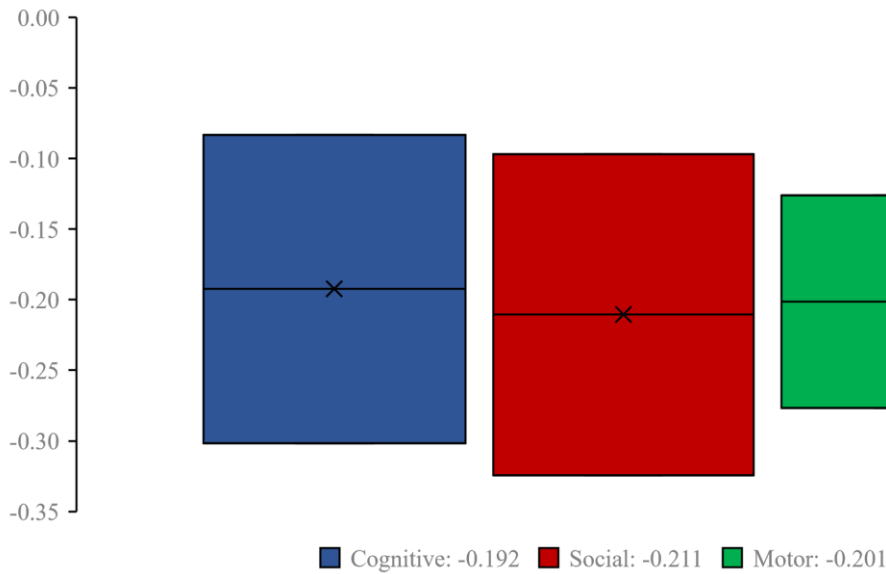
O objetivo dessa seção é verificar se há evidências de convergência condicional global da intensidade das habilidades. O indicador utilizado para esta análise é a intensidade das habilidades, que leva em consideração tanto a escolaridade média quanto as habilidades médias necessárias nas ocupações industriais. A suposição básica é que quanto mais intensas as habilidades das ocupações, maior será a intensidade da sofisticação industrial nessas regiões.

A Figura 21 apresenta os resultados da estimação das equações de convergência dos modelos finais²⁶. As colunas representam os efeitos marginais totais (Apêndice E – Tabelas E.11) do parâmetro beta do melhor modelo econométrico espacial para cada intensidade das habilidades e seus respectivos intervalos de confiança. O preenchimento das colunas representa cada intensidade das habilidades: cognitiva (preenchimento em azul); social (preenchimento em

²⁶ Seguindo o fluxograma metodológico apresentado na seção 3.9 do capítulo 3, a Tabela E.10 do Apêndice E apresenta os resultados completos das estimações dos modelos espaciais de convergência para a média de intensidade das habilidades, bem como os testes de autocorrelação espacial e os testes de restrição de parâmetro para a escolha dos modelos espaciais.

vermelho); e motora (preenchimento em verde). As colunas preenchidas significam que os parâmetros foram estatisticamente significativos, com p-valor de até 10%.

Figura 21: β - convergência das intensidades de habilidades da indústria



Fonte: elaborado pelo autor (2023).

As evidências encontradas mostram que há convergência condicional global das intensidades de habilidades. Ou seja, há uma correlação negativa entre as notas iniciais das intensidades de habilidades e suas respectivas taxas de crescimento, indicando que as RGI que possuíam níveis menores das intensidades de habilidades na indústria obtiveram maiores taxas de crescimento. O tamanho do parâmetro beta é maior para as habilidades sociais (-0.211), seguido das habilidades motoras (-0.201) e das habilidades cognitivas (-0.192). Entretanto, não há diferenças estatisticamente significativas entre os tipos das intensidades de habilidades (Tabela 13).

Tabela 13: Teste t para a convergência global das habilidades

$$H_0: \beta_1 - \beta_2 = 0$$

$$H_1: \beta_1 - \beta_2 \neq 0$$

$$t_* \pm 1.96$$

	Intensidade de habilidades		
	cognitivas vs. sociais	cognitivas vs. motoras	motoras vs. sociais
t_0	0.331	-0.163	0.244

Fonte: elaborado pelo autor (2023).

4.2.4 Comparações dos resultados das análises de convergência condicional global

As evidências mostram que, ao longo do período de 2003 a 2019 houve convergência condicional global tanto nas habilidades cognitivas, sociais e motoras para a média, mediana e média do último quartil. Para a média geral e a mediana, as habilidades sociais se destacam, enquanto para a média do último quartil, as habilidades cognitivas são o destaque. As evidências também apontam convergência condicional global para a escolaridade média dos trabalhadores, bem como na intensidade das habilidades da indústria.

As evidências mostram que regiões com níveis mais baixos desses indicadores tiveram maiores taxas de crescimento, indicando maior homogeneização das habilidades, da escolaridade e das intensidades na indústria. No entanto, as taxas de convergência variaram entre os diferentes tipos de habilidades, com as habilidades sociais apresentando as maiores taxas de convergência em comparação com as habilidades cognitivas e motoras. Além disso, a escolaridade teve taxa de convergência mais lenta em comparação com as habilidades, sugerindo que as habilidades na indústria podem estar mudando mais rapidamente do que a escolaridade.

De fato, o que as evidências econométricas espaciais mostram está em linha com as evidências da Figura 12 apresentadas na seção 2.2, em que se destacou que as habilidades motoras apresentam níveis maiores do que as demais habilidades para todas as regiões, mas vêm diminuindo ao longo dos anos, ao passo que as demais habilidades e a escolaridade vêm aumentando significativamente durante o período. Da mesma forma, a Figura 13 da seção 4.1 apresenta que os níveis médios das habilidades motoras são maiores que as demais habilidades para 2003 e que o β -convergência entre 2003 e 2019 é menor para as habilidades motoras em comparação com as demais habilidades.

As evidências podem ser sintetizadas em cinco pontos:

- I. As habilidades das ocupações industriais estão ficando mais semelhantes, uma vez que há convergência global das habilidades;
- II. A escolaridade das ocupações está ficando mais semelhante, uma vez que há convergência global da escolaridade;
- III. As intensidades de habilidades das ocupações estão ficando mais semelhantes, uma vez que há convergência global das intensidades de habilidades;
- IV. A escolaridade média dos trabalhadores da indústria aumentou no período;

- V. As médias das habilidades sociais e cognitivas dos trabalhadores da indústria aumentou no período, ao passo que as habilidades motoras se reduziram;

Portanto, as evidências sugerem um aumento na escolaridade dos trabalhadores e uma transição das habilidades motoras para as habilidades sociais e cognitivas durante o período.

Esse ponto suscita reflexões importantes, pois espera-se que no longo prazo a escolaridade média aumente, porém não se sabe o que acontecerá com as habilidades dos trabalhadores das indústrias em suas ocupações. Isso dependerá de inúmeras condições econômicas (macroeconômicas, microeconômicas, mudanças tecnológicas e de economia política) e do próprio desenvolvimento da indústria e do seu modo de produção, como o avanço da indústria 4.0, da internet das coisas, 5G etc. (Schwab, 2017; Schwab & Davis, 2019). Desta forma, olhar para a sofisticação das ocupações é uma nova forma de avaliar a dinâmica do mercado de trabalho na indústria instalada nas RGI.

4.3 TESTE DE ROBUSTEZ PARA A CONVERGÊNCIA CONDICIONAL GLOBAL

Esta seção apresenta os resultados do σ -convergência (CV) e dos kernels estocásticos para as habilidades, escolaridade e para as intensidades de habilidades. A σ -convergência permite determinar se as habilidades, escolaridade e intensidades dos trabalhadores da indústria estão se tornando cada vez mais semelhantes entre as RGI. Como apontado por Sala-I-Marin (1996), as convergências β e σ precisam ser consideradas em conjunto. O uso dos de kernels estocásticos ajuda a capturar a evolução temporal do comportamento de toda a distribuição transversal das habilidades.

4.3.1 Análises de robustez para a convergência condicional global das habilidades

Os resultados para a σ -convergência (CV) e o teste de Silverman para os kernels estocásticos estão apresentados na Tabela 14. Em geral, comparando o CV das habilidades em 2003 com 2019, percebe-se uma diminuição significativa no CV, ou seja, na dispersão das habilidades dos trabalhadores da indústria entre os anos comparados. Com destaque de maiores reduções para as habilidades sociais e motoras para a média geral, habilidades motoras e sociais para a mediana e para as habilidades sociais e cognitivas para a média do último quartil.

Tabela 14: σ – Convergência e Teste de Silverman para as habilidades

Tipo	Habilidades	CV			Teste de Silverman	
		2003	2019	Varição	Critical bandwidth	p-value
Média	Cognitivas	10.153	9.1798	-0.974	0.07	0.326
	Sociais	14.324	11.349	-2.974	0.043	0.682
	Motoras	8.0481	6.001	-2.046	0.066	0.334
Mediana	Cognitivas	12.345	11.71	-0.635	0.168	0.238
	Sociais	17.002	16.18	-0.822	0.088	0.028
	Motoras	10.929	9.851	-1.077	0.08	0.236
Média do último quartil	Cognitivas	5.127	3.593	-1.534	0.096	0.202
	Sociais	9.207	5.731	-3.476	0.037	0.704
	Motoras	3.221	2.948	-0.273	0.055	0.344

Fonte: elaborado pelo autor (2023).

O teste de Silverman aplicado sobre os kernels estocásticos investiga a quantidade de modas existentes na distribuição univariada das habilidades, por meio de estimativas da densidade analisadas via teste de hipótese, com hipótese nula de que a distribuição possui uma moda (unimodal), contra a alternativa de ter mais do que uma moda (multimodal). De maneira geral, os resultados não rejeitam a hipótese nula de que a distribuição das habilidades possui uma moda, ou seja, são unimodais. Desta forma, a média é uma boa medida de tendência central para as análises econométricas apresentadas e para os exercícios de robustez²⁷. Esse resultado não é válido para o kernel das habilidades sociais considerando a mediana como medida. Para esse caso, rejeita-se a hipótese nula de que a distribuição é unimodal.

As estimativas de kernel e o gráfico de contorno permitem verificar o processo de convergência nas caudas da distribuição (em seus pontos mais altos e mais baixos). Os kernels estocásticos mostraram mudanças, algumas significativas e outras não, nas distribuições (desvios da média) de habilidades em 2003 em comparação com 2019. A Figura 22 (a) apresenta os estimativa de densidade de kernel univariada e gráfico de contorno para 2003 e 2019. De maneira geral, as distribuições se tornaram mais leptocúrticas (mais altas e concentradas) entre os anos, evidenciando que os valores das distribuições em 2019 se encontram mais próximos da média do que em 2003, corroborando as evidências de convergência condicional global das

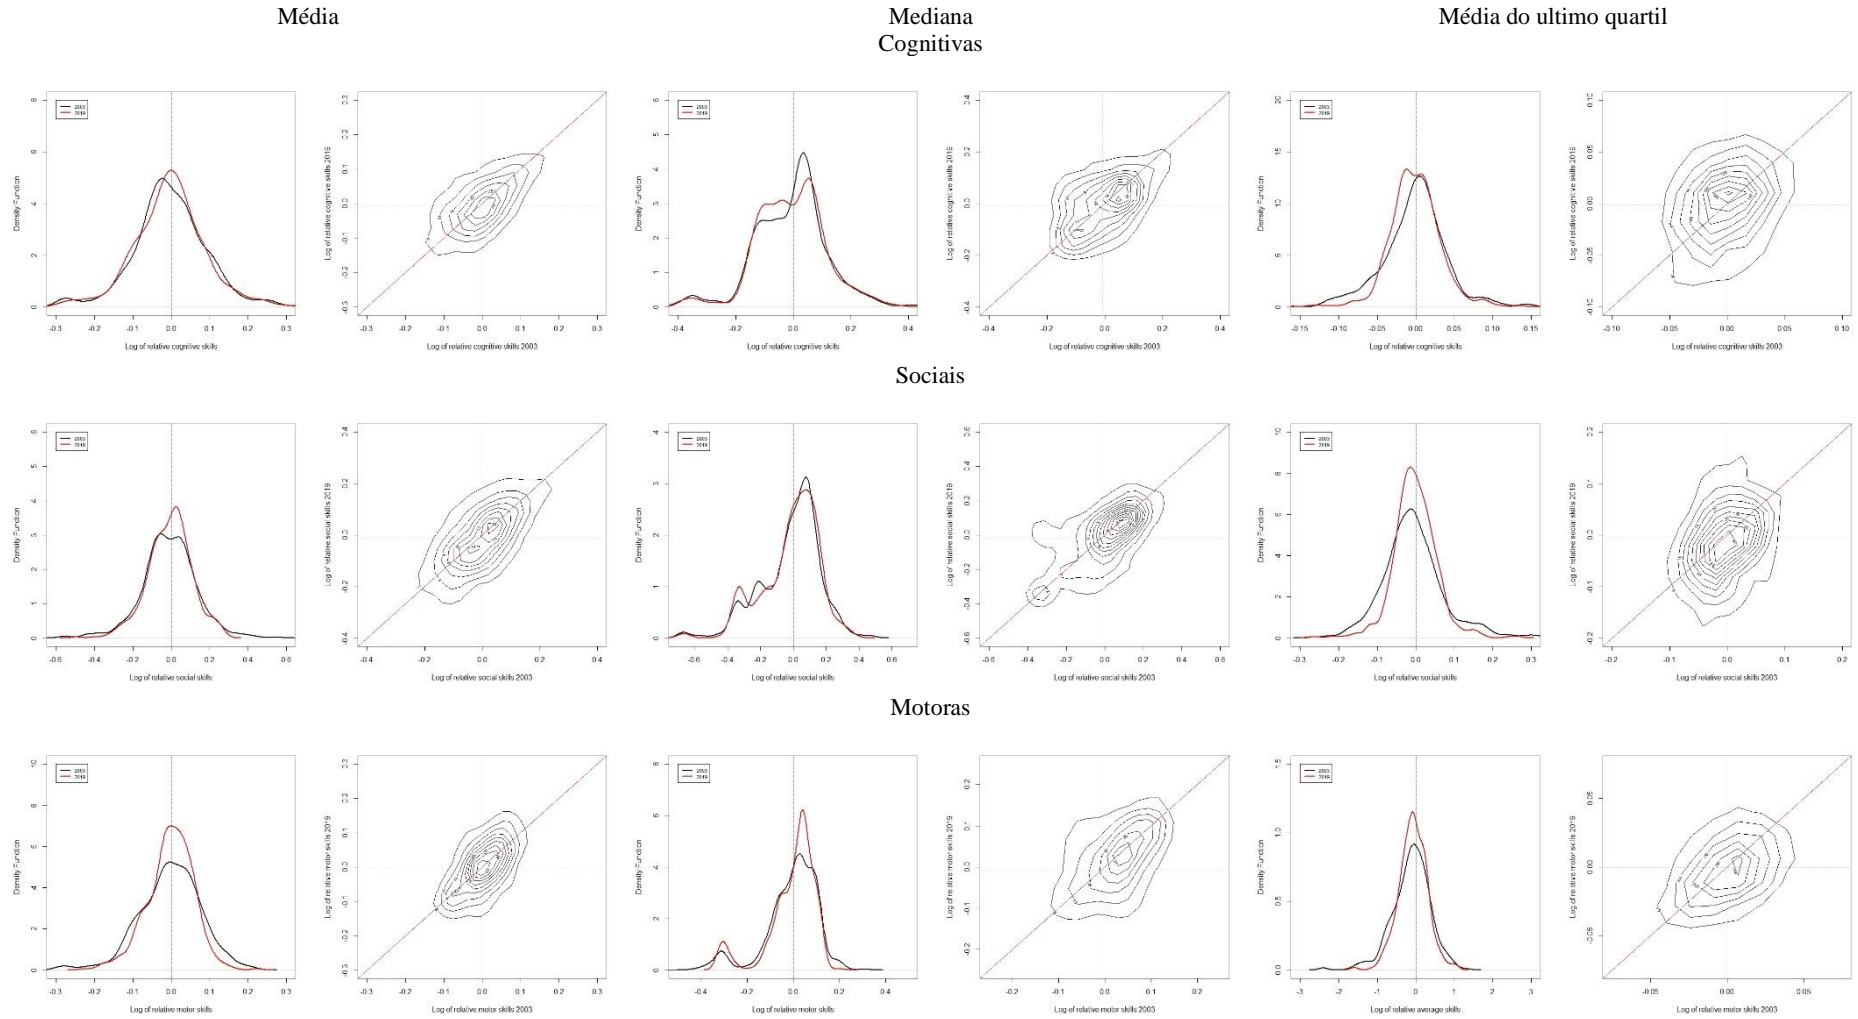
²⁷ Na teoria econômica da convergência, a média desempenha um papel importante, refletindo a tendência de crescimento mais rápido em regiões mais escassas, buscando uma convergência a longo prazo. No entanto, a escolha da medida de tendência central deve considerar o contexto específico da análise e os objetivos da pesquisa. Em alguns casos, medidas alternativas, como a mediana, podem ser mais apropriadas, especialmente diante de preocupações com outliers que possam distorcer a interpretação dos resultados. Para o caso desta tese, a média se mostrou um bom indicador para as análises.

habilidades. Destaque para os kernels das habilidades sociais e motoras para a média geral e habilidades sociais e motoras para a média do último quartil. Já para a mediana, o destaque ficou para as habilidades motoras.

Os gráficos de contorno (Figura 22 (b)) apresentam convergência, pois a maior parte dos gráficos estão em torno da média do eixo de 2019 e paralelo a 2003. Isso é mais visível para as figuras que representam a média do último quartil e menos visível para as demais figuras. Por fim, a análise intradistribuição pode ser realizada buscando a formação de modas separadas, um sinal de estratificação de polarização na distribuição, como apresentado para as habilidades sociais para os dados da mediana.

Portanto, os resultados desta seção corroboram as evidências encontradas na seção anterior, de que há convergência condicional global de habilidades na indústria nas RGI brasileiras no período em análise.

Figura 22: Estimativa de densidade de kernel univariada (A) e gráfico de contorno (B), para as habilidades em 2003 e 2019



Fonte: elaborado pelo autor (2023).

4.3.2 Análises de Robustez para a convergência condicional global da escolaridade

Os resultados para o σ -convergência (CV) e o teste de Silverman para os kernels estocásticos para a escolaridade média dos trabalhadores da indústria estão apresentados na Tabela 15. Por meio da σ -convergência é possível verificar se a escolaridade média exigida pela indústria está se tornando mais uniforme entre as RGI. Percebe-se uma diminuição significativa no CV entre 2003 e 2019, indicando redução na dispersão da escolaridade dos trabalhadores da indústria entre os anos comparados. Essa redução na dispersão é maior em comparação com as habilidades. Os resultados do teste de Silverman não rejeitam a hipótese nula de que a distribuição da escolaridade é unimodal. Portanto, a média se mostra uma medida adequada de tendência central para a análise de robustez.

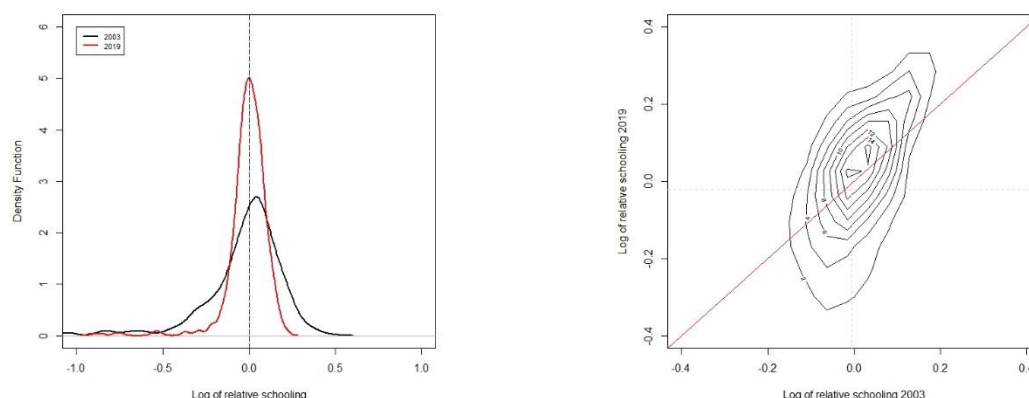
Tabela 15: σ – Convergência e Teste de Silverman para a escolaridade

Variável	CV			Teste de Silverman	
	2003	2019	variação	Critical bandwidth	p-value
Escolaridade	18.96005	10.20139	-8.75866	0.098755	0.582

Fonte: elaborado pelo autor (2023).

As estimativas de kernel e o gráfico de contorno possibilitam a avaliação do processo de convergência nas caudas da distribuição, tanto em seus pontos mais elevados quanto mais baixos. Os kernels estocásticos revelam mudanças significativas nas distribuições, indicando desvios em relação à média da escolaridade média dos trabalhadores. A Figura 23 exibe as estimativas da densidade de kernel univariadas e o gráfico de contorno para os anos de 2003 e 2019. A distribuição da escolaridade tornou-se mais leptocúrtica, ou seja, mais alta e concentrada, ao longo desse período, evidenciando que os valores das distribuições em 2019 estão mais próximos da média do que em 2003. Esses resultados corroboram as evidências de convergência condicional global apresentadas na análise de regressão espacial.

Figura 23: Estimativa de densidade de kernel univariada (A) e gráfico de contorno (B), para a escolaridade em 2003 e 2019



Fonte: elaborado pelo autor (2023).



A diagonal principal dos gráficos de contorno (Figura 23) representa convergência, pois a maior parte do gráfico está em torno da média do eixo de 2019 e paralelo a 2003. Por fim, a análise intra-distribuição indica que não há formação de modas separados, ou seja, não há um sinal de estratificação de polarização na distribuição da escolaridade. Portanto, as evidências desta seção sugerem também que há convergência de escolaridade dos trabalhadores da indústria no período em análise.

4.3.3 Análises de Robustez para a convergência condicional global de intensidades de habilidades

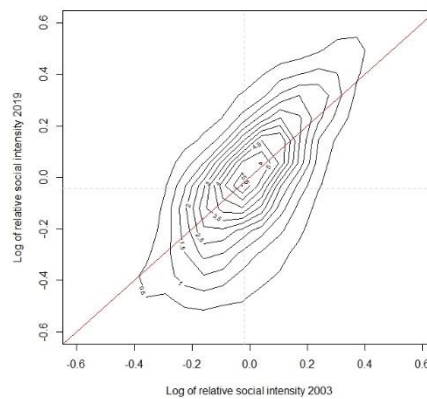

Os resultados para σ -convergência (CV) e o teste de Silverman para os kernels estocásticos estão apresentados na Tabela 16. Em geral, comparando o CV das intensidades de habilidades em 2003 com 2019, percebe-se uma diminuição significativa da dispersão das intensidades de habilidades dos trabalhadores da indústria entre os anos comparados. O teste de Silverman aplicado sobre os kernels estocásticos não rejeitam a hipótese nula de que a distribuição das intensidades de habilidades seja unimodal. Desta forma, a média também é uma boa medida de tendência central para essa análise de robustez das intensidades.

Figura 24: Estimativa de densidade de kernel univariada (A) e gráfico de contorno (B) para as intensidades de habilidades em 2003 e 2019


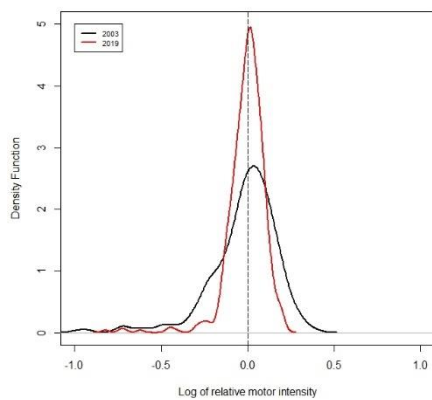
cognitivas



sociais



motoras



Fonte: elaborado pelo autor (2023).

Tabela 16: σ – Convergência e Teste de Silverman para a intensidade de habilidades

Intensidade	CV			Teste de Silverman	
	2003	2019	variação	Critical bandwidth	p-value
Cognitiva	26.252	17.125	-9.127	0.0917	0.932
Social	27.713	18.177	-9.536	0.0932	0.894
Motora	17.315	9.966	-7.349	0.0836	0.660

Fonte: elaborado pelo autor (2023).

A Figura 24 exibe as estimativas da densidade de kernel univariada e o gráfico de contorno para os anos de 2003 e 2019, focalizando nas intensidades de habilidades. As distribuições tornaram-se mais leptocúrticas, ou seja, mais altas e concentradas, ao longo desses anos, indicando que os valores das distribuições em 2019 estão mais próximos da média do que em 2003. Isso reforça as evidências de convergência condicional global. Os gráficos de contorno na Figura 24 mostram convergência, pois os elementos na distribuição *cross-section* estão próximos à média do eixo de 2019 e paralelos a 2003. Portanto, esses resultados corroboram as evidências encontradas na seção anterior, confirmando a presença de convergência condicional global nas intensidades de habilidades na indústria.

Em resumo, a análise das medidas de σ -convergência, do teste de Silverman e dos gráficos de densidade de kernel e de contorno revela uma clara tendência de convergência nas habilidades, escolaridade e intensidades exigidas pela indústria entre 2003 e 2019. Observa-se uma notável redução na dispersão das variáveis analisadas, indicando maior uniformidade. Além disso, os gráficos de kernel mostram que as distribuições das variáveis se tornaram mais leptocúrticas, evidenciando que os valores em 2019 estão mais próximos da média do que em 2003. Os gráficos de contorno demonstram que a maioria das distribuições se concentra em torno da média de 2003, com paralelismo em relação a 2019, reforçando a evidência de convergência. Esses resultados confirmam as conclusões das seções 4.2.1 a 4.2.4, destacando as evidências de convergência condicional global nas habilidades, escolaridade e intensidades exigidas pela indústria no Brasil ao longo do período analisado.

4.4 HETEROGENEIDADE SETORIAL

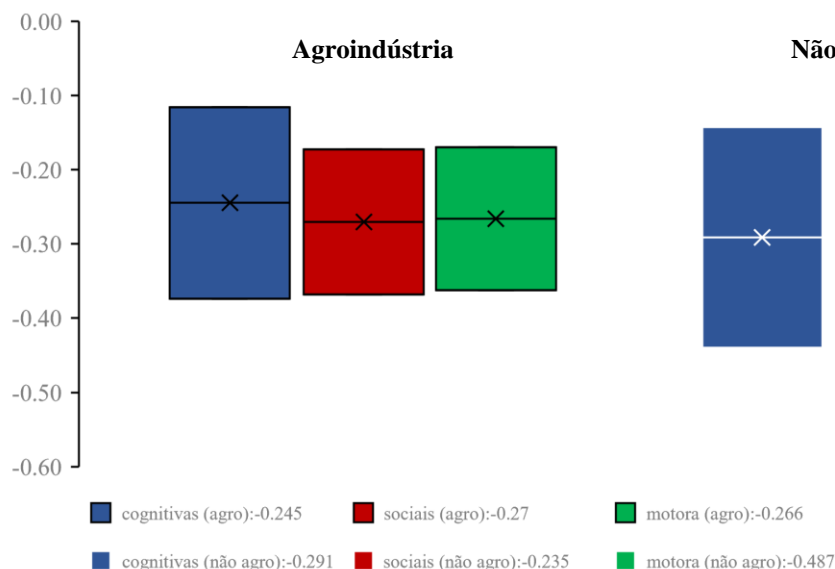
Nesta tese, é sustentada a argumentação de que o nível de habilidades das ocupações na indústria em uma região está intrinsecamente ligado ao tipo de indústria presente no local. Se uma indústria emprega métodos de produção mais simples, é de se esperar que necessite de

trabalhadores em ocupações menos sofisticadas e complexas, o que reflete as características específicas da indústria na região. Esta seção traz as evidências econométricas da convergência condicional global para as habilidades, escolaridade e intensidades estratificada de duas maneiras: 1 – Agroindústria (1) e Não Agroindústria (2); 2 – Indústria intensiva em Capital (3) e Indústria intensiva em Trabalho (4). Assim como na seção 4.2, a escolha da matriz espacial pelo critério “*goodness-of-fit*” está disponível no Apêndice F (Tabela F.1, F.6, F.11, F.18 e F.23). Seguindo o fluxograma metodológico, as Tabelas do Apêndice F apresentam os resultados completos das estimações dos modelos espaciais, bem como os testes de autocorrelação e dependência espacial, de restrição de parâmetro para a escolha dos modelos espaciais e os resultados dos efeitos marginais. Inicialmente, apresentam-se as estimativas de convergência das médias das habilidades dos trabalhadores; em seguida apresentam-se as estimativas para a escolaridade e, por último, para a intensidade de habilidades.

4.4.1 Heterogeneidade setorial para as habilidades

Nesta seção apresentam-se as estimativas de convergência condicional global distinguindo a agroindústria dos demais setores e as indústrias intensivas em capital das intensivas em trabalho. Com o objetivo de facilitar as análises, a Figura 25 apresenta os parâmetros de β -convergência. De acordo com o fluxograma metodológico²⁸, as colunas da figura representam os parâmetros beta e seus respectivos intervalos de confiança referentes aos modelos econométricos espaciais finais. O contorno das colunas representa cada grupo: 1 - Agroindústria (contorno em preto) e 2 - Não agroindústria (contorno em branco). O preenchimento das colunas representa cada habilidade: cognitiva (preenchimento em azul), social (vermelho) e motora (verde). Colunas preenchidas indicam que os parâmetros foram estatisticamente significativos, com p-valor de até 10%. Esses resultados estão nas Tabelas F.2, F.3, F.4 e F.5 do Apêndice F.

²⁸ Seção 3.9 do capítulo 3.

Figura 25: β -convergência das habilidades na agroindústria e não agroindústria

Fonte: elaborado pelo autor (2023).

A Figura 25 mostra que há evidências de convergência condicional das habilidades para a agroindústria e para os demais setores industriais. Entretanto, o tamanho do parâmetro beta é diferente entres eles. Para a agroindústria, os parâmetros são maiores para as habilidades sociais (-0.270), seguidas pelas motoras (-0.266) e cognitivas (-0.245). Já para a não agroindústria, os parâmetros são maiores para as habilidades motoras (-0.487), vindo a seguir as cognitivas (-0.291) e sociais (-0.235). Os parâmetros para as habilidades cognitivas e motoras são maiores para a não agroindústria, enquanto para as habilidades sociais o parâmetro é maior para a agroindústria.

Os resultados da Tabela 17 apresentam que há diferenças entre os parâmetros de convergência intragrupos e intergrupos. Para a Agroindústria (contorno em preto), não se rejeitam as hipóteses nulas de que os parâmetros são iguais entre as habilidades. Já para a Não Agroindústria (contorno em branco) não se rejeita a hipótese nula de igualdade nos parâmetros para entre as habilidades cognitivas vs. sociais; para o restante, rejeita-se a hipótese nula de igualdade. A análise intergrupos compara os parâmetros das regressões entre as habilidades cognitivas, sociais e motoras da indústria do agronegócio vs. não agronegócio com o teste t não pareado²⁹. Os resultados da Tabela 17 apresentam que os parâmetros são estatisticamente diferentes entre os grupos.

²⁹ Já descrito na seção 4.2.1.

Tabela 17: Teste t para a convergência das habilidades na agroindústria e não agroindústria

$H_0: \beta_1 - \beta_2 = 0$			
$H_0: \beta_1 - \beta_2 \neq 0$			
$t_* \pm 1.96$			
Agroindústria			
	cognitivas vs. sociais	cognitivas vs. motoras	motoras vs. sociais
t_0	0.39	0.33	0.09
Não agroindústria			
	cognitivas vs. sociais	cognitivas vs. motoras	motoras vs. sociais
t_0	-0.74	2.60	-6.93
Agroindústria vs. Não agroindústria			
	cognitivas	sociais	motoras
t_0	40.38	314.92	-39.97

Fonte: elaborado pelo autor (2023).

Desta forma, apesar de os parâmetros do β -convergência condicional global serem todos negativos e significativos para ambos os grupos de setores, são estatisticamente diferentes entre si. Essas evidências implicam em dinâmicas diferentes de convergência, resultando em velocidade anual implícita e meia-vida diferentes entre os grupos industriais. Os resultados da Tabela 18 mostram que a velocidade da convergência para as habilidades na agroindústria é maior para as habilidades motoras (0.025), seguida das habilidades sociais (0.024) e cognitivas (0.022). Já na não agroindústria, é maior para as habilidades motoras (0.051), seguida das habilidades cognitivas (0.026) e sociais (0.021). O tempo necessário para que a diferença entre as regiões se reduza pela metade (meia-vida) para a agroindústria é de 13,9 anos para habilidades cognitivas, de 12,6 para as habilidades motoras e 12,4 para as habilidades sociais. Para a não agroindústria, o tempo necessário é de 5,9 anos para as habilidades motoras, seguido de 11,4 para as habilidades cognitivas e 14,6 para as habilidades sociais.

Tabela 18: Velocidade anual implícita de convergência (φ) e Meia-Vida (anos) para a agroindústria e não agroindústria

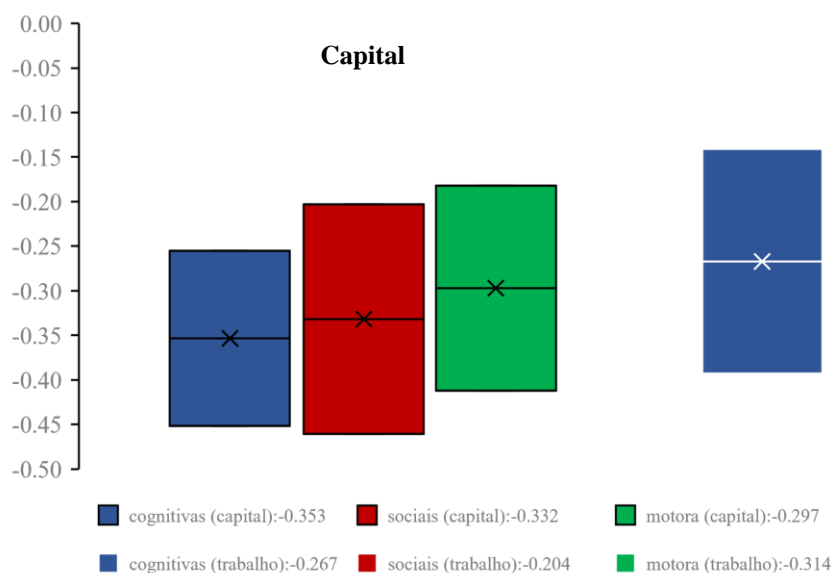
Grupos	Cognitivas		Sociais		Motoras	
	φ	Meia-Vida	φ	Meia-Vida	φ	Meia-Vida
Agronegócio	0.022	13.945	0.024	12.417	0.025	12.655
Não agronegócio	0.026	11.387	0.021	14.615	0.051	5.864

Fonte: elaborado pelo autor (2023).

A Figura 26 apresenta comparações entre os parâmetros das indústrias intensivas em capital e em trabalho. As colunas do gráfico representam os efeitos totais dos parâmetros beta obtidos

nos melhores modelos econométricos espaciais para cada grupo e para cada habilidade, como detalhado nas Tabelas F.8 e F.10 do Apêndice F. Os detalhes das matrizes espaciais e os resultados das regressões podem ser encontrados nas Tabelas F.6, F.7 e F.9 do mesmo apêndice.

Figura 26: β -convergência das habilidades nas indústrias intensivas em capital e em trabalho



Fonte: elaborado pelo autor (2023).

A Figura 26 mostra evidências de convergência condicional tanto para as indústrias intensivas em capital quanto para as intensivas em trabalho. No entanto, os valores dos parâmetros beta variam entre esses dois grupos. Na indústria intensiva em capital, a ordenação dos valores de parâmetros observados para as habilidades é: cognitivas (-0.353), sociais (-0.332) e motoras (-0.297). Já na indústria intensiva em trabalho a ordem muda, com a ordem dos valores de parâmetros sendo: habilidades motoras (-0.314), cognitivas (-0.267) e sociais (-0.204).

A comparação entre os dois grupos indica que os valores dos parâmetros são mais negativos na indústria intensiva em capital em comparação com a indústria intensiva em trabalho nas habilidades cognitivas e sociais. Para as habilidades motoras ocorre o inverso.

Os resultados da Tabela 19 apresentam que há diferenças entre os parâmetros de convergência intragrupos e intergrupos. Para grupo 3 (intensivo em capital - contorno em preto), não se rejeita a hipótese de igualdade entre as habilidades deste grupo. A análise é a mesma para o grupo 4 (intensivo em trabalho – contorno em branco), ou seja, não se rejeita a hipótese nula de que os

parâmetros de convergência condicional são iguais entre todas as habilidades. A análise intergrupos compara os parâmetros das regressões entre as habilidades cognitivas, sociais e motoras da indústria intensiva em capital e intensiva em trabalho com o teste t independente. Os resultados da Tabela 19 apresentam que os parâmetros são estatisticamente diferentes entre os grupos.

Tabela 19: Teste t para a convergência das habilidades para as indústrias intensivas em capital e intensivas em trabalho

$H_0: \beta_1 - \beta_2 = 0$			
$H_0: \beta_1 - \beta_2 \neq 0$			
$t_* \pm 1.96$			
Capital intensivo			
	cognitivas vs. sociais	cognitivas vs. motoras	motoras vs. sociais
t_0	-0.43	-1.14	0.60
Trabalho intensivo			
	cognitivas vs. sociais	cognitivas vs. motoras	motoras vs. sociais
t_0	-0.99	0.74	-1.66
Capital intensivo vs. Trabalho intensivo			
	cognitivas	sociais	motoras
t_0	-90.30	-129.239	16.416

Fonte: elaborado pelo autor (2023).

Desta forma, apesar de os parâmetros do β -convergência condicional global serem todos negativos e significativos para ambos os grupos, são estatisticamente diferentes. Essas evidências implicam em dinâmicas diferentes de convergência, resultando em velocidade anual implícita e meia-vida diferentes entre os grupos industriais (Tabela 20).

Tabela 20: Velocidade anual implícita de convergência (φ) e Meia-Vida (anos) para as indústrias intensivas em capital e intensivas em trabalho

Grupos	Cognitivas		Sociais		Motoras	
	φ	Meia-Vida	φ	Meia-Vida	φ	Meia-Vida
Capital intensivo	0.034	8.977	0.031	9.699	0.027	11.106
Trabalho intensivo	0.024	12.605	0.018	17.175	0.029	10.379

Fonte: elaborado pelo autor (2023).

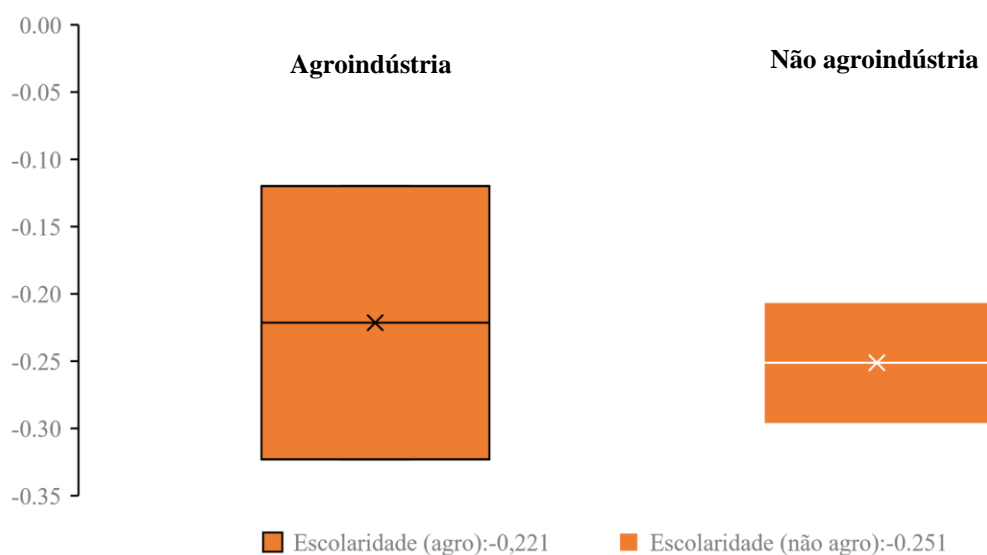
Os resultados da Tabela 20 indicam que a velocidade da convergência da indústria intensiva em capital é maior para as habilidades cognitivas (0.034), seguida das habilidades sociais (0.031) e motoras (0.027). Já a velocidade média para as habilidades da indústria intensiva em trabalho é maior para as habilidades motoras (0.029), seguida das habilidades cognitivas

(0.024) e sociais (0.018). O tempo necessário para que a diferença entre as regiões se reduza pela metade (meia-vida) para as indústrias intensivas em capital é de 8,9 anos para as habilidades cognitivas, de 9,7 para as habilidades sociais e 11,1 para as habilidades motoras. As análises para as indústrias intensivas em trabalho mostram que o tempo necessário é de 10,4 anos para as habilidades motoras, de 10,4 para as habilidades motoras e 17,2 para as habilidades sociais.

4.4.2 Heterogeneidade setorial para a escolaridade

O objetivo desta análise é verificar a convergência condicional global da escolaridade dos trabalhadores entre os mesmos grupos de setores analisados anteriormente. A Figura 27 apresenta evidências de convergência condicional global da escolaridade para ambas as categorias³⁰. Os gráficos representam os efeitos totais dos parâmetros das regressões (constantes nas Tabela F.13 e F.15, no apêndice F) para a agroindústria (contorno em preto) e a não agroindústria (contorno em branco). As colunas preenchidas em laranja indicam que o efeito total do β -convergência foi estatisticamente significativo, com p-valor de até 10%. Esses resultados estão nas Tabelas F.11, F.12 e F.14 do Apêndice F. Os resultados mostram que, para a agroindústria, o parâmetro foi de -0.221, enquanto para a não agroindústria, o parâmetro foi de -0.251.

Figura 27: β -convergência da escolaridade na agroindústria e não agroindústria



Fonte: elaborado pelo autor (2023).

³⁰ Conforme o fluxograma metodológico da seção 3.9 do capítulo 3.

Os resultados da Tabela 21 (Teste t independente) indicam que há diferenças entre os parâmetros de convergência de escolaridade intergrupos, ou seja, rejeita-se a hipótese nula de que os parâmetros de convergência condicional global são iguais entre a escolaridade dos trabalhadores da agroindústria e não agroindústria.

Tabela 21: Teste t para a convergência de escolaridade na agroindústria e não agroindústria

$H_0: \beta_1 - \beta_2 = 0$	
$H_0: \beta_1 - \beta_2 \neq 0$	
$t_* \pm 1.96$	
agroindústria vs. não agroindústria	
Escolaridade	
t_0	16.95

Fonte: elaborado pelo autor (2023).

A Tabela 22 apresenta os indicadores de velocidade implícita e meia-vida, mostrando que a velocidade da convergência para a escolaridade da não agroindústria (0.022) é maior do que a velocidade da não agroindústria (0.019). O tempo necessário para que a diferença entre as RGI se reduza pela metade (meia-vida) é de 13,5 anos para a não agroindústria e 15,6 anos para a agroindústria.

Tabela 22: Velocidade anual implícita de convergência (φ) e Meia-Vida (anos) para a escolaridade da agroindústria e não agroindústria

Indústrias	Escolaridade	
	φ	Meia-Vida
Agroindústria	0.019	15.646
Não agroindústria	0.022	13.526


Fonte: elaborado pelo autor (2023).

A Figura 28 exibe as comparações dos parâmetros de convergência da escolaridade entre as indústrias intensivas em capital e as intensivas em trabalho. Seguindo o fluxograma metodológico³¹, cada coluna nos gráficos representa os efeitos totais dos parâmetros beta, conforme detalhado no Apêndice F, Tabelas F.17 e F.19, para ambos os grupos: intensivas em capital (contorno em preto) e intensivas em trabalho (contorno em branco). Colunas preenchidas em laranja indicam que o efeito total do β -convergência foi estatisticamente

³¹ Seção 3.9 do capítulo 3.

significativo, com um p-valor de até 10%. Esses resultados estão nas Tabelas F.11, F.16 e F.18 do Apêndice F.

Figura 28: β -convergência das habilidades na indústria intensiva em capital e intensiva em trabalho



Fonte: elaborado pelo autor (2023).

A Figura 28 mostra que há evidências de convergência condicional tanto para as indústrias intensivas em capital como em trabalho. Entretanto, o tamanho do parâmetro beta é diferente entre elas. Para a indústria intensiva em capital o parâmetro é de -0,177 e para a indústria intensiva em trabalho, é de -0,207. Os resultados da Tabela 23 (Teste t independente) mostram que há diferenças entre os parâmetros de convergência de escolaridade intergrupos, ou seja, rejeitam a hipótese nula de que os parâmetros de convergência condicional global de escolaridade são iguais entre a os trabalhadores da indústria intensiva em capital e da intensiva em trabalho.

Tabela 23: Teste t para a convergência da escolaridade na indústria intensiva em capital e intensiva em trabalho

$H_0: \beta_1 - \beta_2 = 0$	
$H_0: \beta_1 - \beta_2 \neq 0$	
$t_* \pm 1.96$	
Capital intensivo vs. Trabalho intensivo	
Escolaridade	
t_0	3.80

Fonte: elaborado pelo autor (2023).

Desta forma, apesar dos parâmetros do β -convergência condicional global serem todos negativos e significativos para ambos os grupos, eles são estatisticamente diferentes. Essas evidências implicam em dinâmicas diferentes de convergência, resultando em velocidade anual implícita e meia-vida diferentes entre os grupos industriais. A Tabela 24 apresenta os indicadores de velocidade implícita e velocidade meia-vida para os resultados dos parâmetros de convergência condicional global da escolaridade para os dois grupos.

Tabela 24: Velocidade anual implícita de convergência (φ) e Meia-Vida (anos) para a escolaridade da indústria intensiva em capital e intensiva em trabalho

Indústrias	Escolaridade	
	φ	Meia-Vida
Capital intensivo	0.015	20.036
Trabalho intensivo	0.018	16.848

Fonte: elaborado pelo autor.

Verifica-se que a velocidade de convergência para a escolaridade da indústria intensiva em trabalho (0.018) é maior do que a velocidade da indústria intensiva em capital (0.018). O tempo necessário para que a diferença entre as regiões se reduza pela metade (meia-vida) é de 16,8 anos para as indústrias intensivas em trabalho e 20 anos para as intensivas em capital.


4.4.3 Heterogeneidade setorial para as intensidades de habilidades

Nesta seção são apresentadas as estimativas de convergência condicional global das médias das intensidades de habilidades nos quatro grupos já analisados. Seguindo o fluxograma metodológico (Seção 3.9 do capítulo 3), a escolha da matriz espacial e as regressões espaciais podem ser visualizadas nas Tabelas F.20, F.21 e F.23 do Apêndice F. Com o intuito de facilitar as análises, a Figura 29 apresenta o parâmetro de β -convergência para as intensidades de

habilidades na agroindústria e na não agroindústria. As colunas do gráfico representam os parâmetros beta e seus intervalos de confiança correspondentes, referentes aos efeitos marginais totais dos modelos econométricos espaciais finais (constantes das Tabelas F.22 e F.24 no apêndice F).

A Figura 29 mostra que há evidências de convergência condicional para a intensidade de habilidades tanto na agroindústria quanto nos demais setores. Entretanto, o tamanho do parâmetro beta é diferente entres eles. Para a agroindústria, os parâmetros são maiores são para as intensidades de habilidades sociais (-0.281), seguidas pelas motoras (-0.251) e cognitivas (-0.247). Já para a não agroindústria, os parâmetros são maiores para as intensidades de habilidades sociais (-0.210), vindo a seguir as cognitivas (-0.106) e motoras (-0.094). Os parâmetros para as intensidades dos três tipos de habilidades são maiores para a agroindústria em comparação com a não agroindústria.

Figura 29: β -convergência para as intensidades de habilidades na agroindústria e não agroindústria



Fonte: elaborado pelo autor (2023).

A Figura 29 mostra que há evidências de convergência condicional para a intensidade de habilidades tanto na agroindústria quanto nos demais setores. Entretanto, o tamanho do parâmetro beta é diferente entres eles. Para a agroindústria, os parâmetros são maiores são para as intensidades de habilidades sociais (-0.281), seguidas pelas motoras (-0.251) e cognitivas (-0.247). Já para a não agroindústria, os parâmetros são maiores para as intensidades de

habilidades sociais (-0.210), vindo a seguir as cognitivas (-0.106) e motoras (-0.094). Os parâmetros para as intensidades dos três tipos de habilidades são maiores para a agroindústria em comparação com a não agroindústria.

Os resultados indicam que há diferenças entre os parâmetros de convergência intragrupos e intergrupos (Tabela 25). Para a Agroindústria (contorno em preto), não se rejeitam as hipóteses nulas de que os parâmetros são iguais entre as intensidades de habilidades. Já para a não agroindústria (contorno em branco), rejeita-se a hipótese nula de igualdade nos parâmetros cognitivas vs. sociais e motoras vs. Sociais; para o restante não se rejeita a hipótese nula de igualdade. A análise intergrupos compara os parâmetros das regressões entre as intensidades de habilidades cognitivas, sociais e motoras da indústria do agronegócio vs. não agronegócio. Os resultados da Tabela 24 indicam que os parâmetros são estatisticamente diferentes entre os grupos.

Tabela 25: Teste t para a convergência das intensidades de habilidades na agroindústria e não agroindústria

$H_0: \beta_1 - \beta_2 = 0$			
$H_0: \beta_1 - \beta_2 \neq 0$			
$t_* \pm 1.96$			
Agronegócio			
	cognitivas vs. sociais	cognitivas vs. motoras	motoras vs. sociais
t_0	0.69	0.09	0.72
Não agronegócio			
	cognitivas vs. sociais	cognitivas vs. motoras	motoras vs. sociais
t_0	2.23	-0.25	3.33
Agronegócio vs. Não agronegócio			
	cognitivas	sociais	motoras
t_0	-171.90	-14.94	-237.36

Fonte: elaborado pelo autor (2023).

Assim, embora os parâmetros da convergência condicional global de β sejam todos negativos e significativos em ambos os setores da indústria, apresentam diferenças estatisticamente significativas. Essas constatações indicam que existem dinâmicas distintas de convergência, o que resulta em velocidades anuais implícitas e meias-vidas diferentes entre os grupos industriais. Os resultados da Tabela 26 mostram que a velocidade da convergência para as intensidades de habilidades da agroindústria é maior para a intensidade de habilidades sociais (0.025), seguida das cognitivas (0.022) e motoras (0.022), que são semelhantes. Já a velocidade

média para a intensidade de habilidades da não agroindústria é maior para as habilidades sociais (0.018), seguida das cognitivas (0.009) e motoras (0.008).

O tempo necessário para que a diferença entre as regiões se reduza pela metade (meia-vida) para a agroindústria é de 11,8 anos para as intensidades de habilidades sociais, seguido de 13,5 para as intensidades de habilidades motoras e 13,8 para as intensidades de habilidades cognitivas. Para a não agroindústria o tempo necessário é de 16.6 anos para as intensidades de habilidades sociais, seguido de 35,0 para as intensidades de habilidades cognitivas e 39,6 para as intensidades de habilidades motoras.

Tabela 26: Velocidade anual implícita de convergência (ϕ) e Meia-Vida (anos) para as intensidades de habilidades para a agroindústria e não agroindústria


Grupos	Cognitivas		Sociais		Motoras	
	ϕ	Meia-Vida	ϕ	Meia-Vida	ϕ	Meia-Vida
Agroindústria	0.022	13.807	0.025	11.862	0.022	13.533
Não agroindústria	0.009	35.016	0.018	16.599	0.008	39.616

Fonte: elaborado pelo autor (2023).

A Figura 30 apresenta as comparações de parâmetros para indústrias intensivas em capital ou em trabalho. As colunas das figuras representam os efeitos totais (Apêndice F -Tabelas F.27 e F.29) do parâmetro beta do melhor modelo econométrico espacial (Apêndice F – Tabela F.26 e Tabela F.28) para cada grupo (3 e 4) e para cada intensidade de habilidade.

A Figura 30 mostra que há evidências de convergência condicional tanto para as indústrias intensivas em capital como em trabalho. Entretanto, o tamanho do parâmetro beta é diferente entre elas. Para a indústria intensiva em capital, os maiores parâmetros são para as intensidades de habilidades sociais (-0.284), seguidas das cognitivas (-0.218) e motoras (-0.154). A ordenação muda para a indústria intensiva em trabalho, com o maior parâmetro sendo para as intensidades de habilidades cognitivas (-0.245), motoras (-0.234) e sociais (-0.229). A comparação entre os dois grupos indica que para todas as intensidades de habilidades, exceto para habilidades sociais, os parâmetros são mais negativos para a indústria intensiva em trabalho em relação à indústria intensiva em capital.

Figura 30: β -convergência das habilidades na indústria intensiva em capital e intensiva em trabalho



Fonte: elaborado pelo autor (2023).

Os resultados da Tabela 27 apresentam que há diferenças entre os parâmetros de convergência intragrupos e intergrupos. Para o grupo 3 (intensivo em capital - contorno em preto), não se rejeita a hipótese de igualdade entre as habilidades deste grupo, exceto entre as intensidades de habilidades motoras vs. sociais. Para grupo 4 (intensivo em trabalho - contorno em branco), não se rejeita a hipótese de igualdade entre as habilidades deste grupo, ou seja, não se rejeita a hipótese nula de que os parâmetros de convergência condicional global são iguais entre todas as intensidades de habilidades. A análise intergrupos compara os parâmetros das regressões entre as intensidades de habilidades cognitivas, sociais e motoras da indústria intensiva em capital e intensiva em trabalho. Os resultados indicam que os parâmetros são estatisticamente diferentes entre os grupos.

Tabela 27: Teste t para a convergência das intensidades de habilidades na indústria intensiva em capital e intensiva em trabalho

$H_0: \beta_1 - \beta_2 = 0$			
$H_0: \beta_1 - \beta_2 \neq 0$			
$t_* \pm 1.96$			
Capital intensivo			
	cognitivas vs. sociais	cognitivas vs. motoras	motoras vs. sociais
t_0	1.06	-1.02	2.25
Trabalho intensivo			
	cognitivas vs. sociais	cognitivas vs. motoras	motoras vs. sociais
t_0	-0.21	-0.14	-0.12
Capital intensivo vs. Trabalho intensivo			
	cognitivas	sociais	motoras
t_0	23.00	-48.16	94.94

Fonte: elaborado pelo autor (2023).

Portanto, apesar de os parâmetros da β -convergência condicional global serem todos negativos e estatisticamente significantes em ambos os setores da indústria, apresentam diferenças estatísticas. Esses achados sugerem a existência de dinâmicas de convergência distintas, resultando em velocidades anuais implícitas e meias-vidas diferentes entre os grupos industriais. Os resultados da Tabela 28 amostram que a velocidade da convergência para as intensidades de habilidades da indústria intensiva em capital é maior para as habilidades sociais (0.026), seguida das habilidades cognitivas (0.019) e motoras (0.013). Já a velocidade média para as habilidades da indústria intensiva em trabalho é maior para as habilidades cognitivas (0.022), seguida das habilidades motoras (0.021) e sociais (0.020).

Tabela 28: Velocidade anual implícita de convergência (φ) e Meia-Vida (anos) para as intensidades de habilidades das indústrias intensivas em capital e intensivas em trabalho

Grupos	Cognitivas		Sociais		Motoras	
	φ	Meia-Vida	φ	Meia-Vida	φ	Meia-Vida
Capital intensivo	0.019	15.948	0.026	11.730	0.013	23.369
Trabalho intensivo	0.022	13.950	0.020	15.072	0.021	14.678

Fonte: elaborado pelo autor (2023).

O tempo necessário para que a diferença entre as regiões se reduza pela metade (meia-vida) para as indústrias intensivas em capital é de 11,7 anos para as intensidades de habilidades sociais, seguido de 15,9 para as intensidades de habilidades cognitivas e 23,4 para as intensidades de habilidades motoras. As análises para as indústrias intensivas em trabalho

mostram que o tempo necessário é de 13,9 anos para as intensidades de habilidades cognitivas, de 14,6 para as intensidades de habilidades motoras e 15,1 para as intensidades de habilidades sociais.

4.4.4 Comparações dos resultados de convergência para a heterogeneidade setorial

Em geral, há diferenças nos parâmetros das habilidades entre os diferentes tipos de indústria, resultando em diferentes velocidades implícitas e meias-vidas. No que diz respeito às habilidades, todas convergem tanto para a agroindústria quanto para a não agroindústria. No entanto, existem diferenças entre os setores. Na agroindústria, o parâmetro de β -convergência é maior para as habilidades sociais, enquanto na não agroindústria, os parâmetros para habilidades motoras e cognitivas são maiores. Nas indústrias intensivas em capital e intensivas em trabalho, todos os parâmetros indicam convergência, porém, os parâmetros são maiores para as habilidades cognitivas e sociais na indústria intensiva em capital, e as habilidades motoras são mais relevantes na indústria intensiva em trabalho.

As possíveis causas podem estar relacionadas ao tipo de indústria que está instalada nas regiões e suas respectivas produtividades, como apontado em Schettini & Azzoni (2013). Analisando a convergência por tipo de indústria, as evidências encontradas corroboram os achados da literatura. Apesar de o agronegócio ser uma indústria que vem ganhando importância, como apontado por Favro & Alves (2020), é um setor intensivo em mão de obra e realiza pouco investimento em P&D, comparado com as demais indústrias (Morceiro, 2019). Por conta desses e outros fatores, a velocidade de convergência é menor para esse tipo de indústria comparada às demais indústrias. Ou seja, regiões com menores níveis de habilidade motoras e cognitivas no setor da não agroindústria possuem maiores taxas de crescimento por habilidades, comparada com as regiões com menores níveis de habilidades nessa indústria. Esse são resultados importantes, uma vez a taxa de crescimento por habilidades na indústria regional determina o grau de sofisticação industrial daquela região e está última parece ser mais acentuada para os setores da não agroindústria.

A mesma análise pode ser feita para as indústrias intensivas em capital, que são caracterizadas pelo seu alto investimento em P&D, em comparação com as demais indústrias. As regiões com menores níveis de habilidades cognitivas e sociais nessa indústria possuem maiores taxas de crescimento por habilidades comparadas com as regiões com menores níveis de habilidades na

indústria intensiva em mão de obra. Quando se trata da convergência global da escolaridade, todas as estratificações convergem, mas o parâmetro de convergência global é maior para a escolaridade na não agroindústria e na indústria intensiva em trabalho, em comparação com a agroindústria e a indústria intensiva em capital, respectivamente.

Ao comparar as intensidades de habilidades, observa-se uma mudança nos parâmetros, sendo todos maiores na agroindústria em comparação com a não agroindústria. Isso implica que a penalidade sofrida da escolaridade pelo indicador de habilidade mudou a dinâmica de convergência da não agroindústria. Também há uma variação nos parâmetros das indústrias intensivas em capital e intensivas em trabalho. Assim, na indústria intensiva em trabalho, os parâmetros são maiores para habilidades cognitivas e motoras, enquanto na indústria intensiva em capital, o parâmetro é maior para habilidades sociais.

Outro ponto importante é que, se há evidência de que a complementariedade entre habilidades e estoque de capital influenciam a produtividade, como apontado por Dawid et al. (2013), a produtividade da indústria nas RGI poderia estar sendo influenciada por habilidades menos sofisticadas, como apontam as evidências deste estudo. Esses resultados poderiam estar transbordando também para o processo de inovação na indústria, conforme as evidências empíricas indicam (Bassanini & Scarpetta 2002; Griffith et al. 2004). Entretanto, é necessária uma investigação mais profunda para esses casos.

Portanto, o tipo de indústria instalada na região poderá determinar a demanda por ocupações mais ou menos sofisticadas. Essa diferença de sofisticação poderá determinar o nível de investimento em P&D e de salário naquelas regiões, com possíveis consequências sobre a atividade econômica local e regional.

4.5 HETEROGENEIDADE REGIONAL

Nesta seção apresentam-se as estimativas dos clubes de convergência condicional das habilidades, escolaridade e intensidades de habilidades. Os clubes foram calculados de acordo com o quintil de emprego formal na indústria, com cada grupo congregando regiões que contemplam 20% do emprego em 2019. O número de empregos é fixo no quintil, porém o número de RGI varia de acordo com cada quintil. O propósito dessa análise é de captar os efeitos das economias de aglomeração sobre a convergência condicional de habilidades e é também uma forma de controlar os resultados pelo tamanho da indústria instalada nas RGI.

Espera-se que diferentes densidades de empregos possam interferir na trajetória de crescimento das habilidades pela indústria nas RGI.

A análise dos quintis mostra como o emprego na indústria é concentrado em algumas RGI: 25% das RGI concentram 82% do emprego (Tabela 29). Conforme discutido na Seção 2.1, a indústria ainda é concentrada nas regiões tradicionalmente industrializadas localizadas no Sudeste e Sul do país (Saboia, 2013, Sobrinho & Azzoni, 2016; Silva & Diniz, 2020). Nas RGI de São Paulo, Campinas, Rio de Janeiro e Belo Horizonte (localizadas na classe de tamanho 1) estão concentrados 20% do emprego total em 2019. Nas RGI de Curitiba - PR, Fortaleza - CE, Sorocaba - SP, Joinville - SC, Novo Hamburgo (São Leopoldo) - RS, Porto Alegre - RS, Recife - PE, Caxias do Sul - RS, Jundiaí - SP, Manaus - AM, São Miguel do Oeste - SC, Salvador - BA, Goiania - GO (classe de tamanho 2) estão concentrados outros 20% do emprego.

Tabela 29: Quintil de emprego industrial nas RGI em 2019

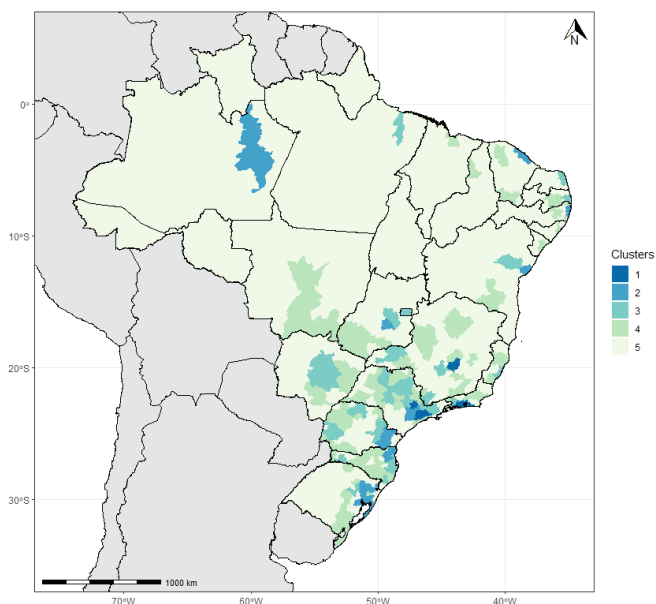
Classe	RGI	(%)	Acumulado (%)	Empregos	(%)	Acumulados (%)
1	4	0.8	0.8	1.497.425	20,8	20,8
2	13	2.6	3.4	1.482.051	20,6	41,3
3	35	6.9	10.3	1.462.381	20,3	61,6
4	77	15,1	25.4	1.442.890	20,0	81,6
5	381	74.7	100	1.322.420	18,4	100
Total	510	100		7.207.167	100	-

Fonte: RAIS (2023).

Nota: os números de empregos e empresas estão divididos por mil.

No cluster 3 e 4 estão localizadas as RGI que pertencem às demais capitais, bem como RGI próximas das capitais e algumas no interior dos estados. Por fim, na última classe de tamanho estão as demais RGI localizadas mais no interior do país e longe das capitais. A distribuição espacial é mostrada na Figura 31, que é semelhante aos resultados da distribuição espacial das AIRs (Aglomerações Industriais Relevantes) com mais de 10 mil empregos industriais em 2018 apresentados no estudo de Diniz & Mendes (2021). Os autores descrevem que houve um alargamento do antigo polígono industrial, formando um novo polígono cujos vértices são Belo Horizonte, Anápolis, Rio Verde, Campo Grande, Foz do Iguaçu, Santa Cruz do Sul, Porto Alegre, Florianópolis, Volta Redonda e Belo Horizontes. Grande parte das AIR estão localizadas dentro dos polígonos, com as demais espalhadas pelo Brasil.

Figura 31: Distribuição espacial do quintil de emprego da indústria em 2019



Fonte: elaborado pelo autor (2023).

4.5.1 Heterogeneidade regional para as habilidades

Esta seção traz as evidências econométricas de clubes de convergência condicional das habilidades das ocupações da indústria, estratificando as RGI por clubes de tamanho. Por exemplo, os resultados das regressões das classes de tamanho para as habilidades cognitivas estão na Tabela 30.

A análise dos resultados segue o roteiro do fluxograma metodológico apresentado na seção 3.9 do capítulo 3. As estatísticas dos testes de LMI, RLMI, LMe e RLMe para os modelos OLS (1) apresentam autocorrelação espacial. Desta forma, a estratégia empírica proposta inicia-se com abordagem econométrica espacial geral por meio do modelo SDM (2). A matriz espacial que apresentou o menor AIC para a convergência das habilidades cognitivas para a classe de tamanho foi a matriz *knn* igual a 23³². O teste de Wald mostra que os parâmetros espaciais do modelo SDM (2) são diferentes aos dos modelos SAR (3) e SEM (4). As estimações do modelo SDM (2) mostram que há efeito *spillover* sobre as RGI, evidenciando pelo parâmetro ρ (0.276).

³² A escolha da matriz espacial se deu pelo critério “goodness-of-fit” e está disponível no Apêndice G (Tabela G.1).

Tabela 30: Resultado das regressões das habilidades cognitivas por classe de tamanho

Var.	OLS (1)	SDM (2)	SAR (3)	SEM (4)
β	-0.380*** (0.031)	-0.390*** (0.031)	-0.379*** (0.031)	-0.387*** (0.032)
βC_1	0.588** (0.252)	0.657*** (0.239)	0.579** (0.241)	0.657** (0.244)
βC_2	0.434** (0.172)	0.264 (0.220)	0.431** (0.171)	0.306 (0.186)
βC_3	-0.367 (0.316)	-0.454 (0.290)	-0.329 (0.304)	-0.372 (0.294)
βC_4	-0.033 (0.291)	-0.057 (0.267)	-0.020 (0.284)	-0.057 (0.274)
θ		0.230*** (0.058)		
θC_1		-0.033 (3.282)		
θC_2		1.833 (1.826)		
θC_3		-1.190 (0.969)		
θC_4		0.695 (0.744)		
ρ		0.276*** (0.053)	0.215*** (0.055)	
λ				0.317*** (0.052)
<i>RGI FE</i>	sim	sim	sim	sim
<i>Time FE</i>	sim	sim	sim	sim
Observations	7872	7872	7872	7872
R2	0.220	0.214	0.190	0.200
LogLik	10730.96	15965.36	15933.47	15954.80
AIC	-21429.92	-31906.7	-31852.93	-31895.59
BIC	-21318.38	-31823.1	-31804.14	-31846.80
LM test, no spatial lag	43.667***			
Robust LM test, no spatial lag	42.493***			
LM test, no spatial error	102.19***			
Robust LM test, no spatial error	101.01***			
Teste de Wald	Prob>Chi2	Resultado		
$\theta = 0$ and $\rho \neq 0$	0.0000	SAR \neq SDM		
$\theta = -\beta\rho$	0.0148	SEM \neq SDM		

Fonte: elaborado pelo autor (2023). Nota: nível de significância ***<0.01; **<0.05 e *<0.1. Erro Padrão Robusto.

Os efeitos marginais do modelo SDM foram calculados e analisados (Tabela 31). Considerando o impacto direto e indireto e total do β -convergência condicional das habilidades cognitivas para os clusters de tamanho da indústria. As evidências apontam para convergência de habilidades cognitivas para as RGI da classe de tamanho 5 (classe de tamanho de referência), uma vez que o β -convergencia total para essa classe de tamanho é de -0.216.

Tabela 31: Efeito direto, indireto e total do modelo SDM para as habilidades cognitivas por classe de tamanho

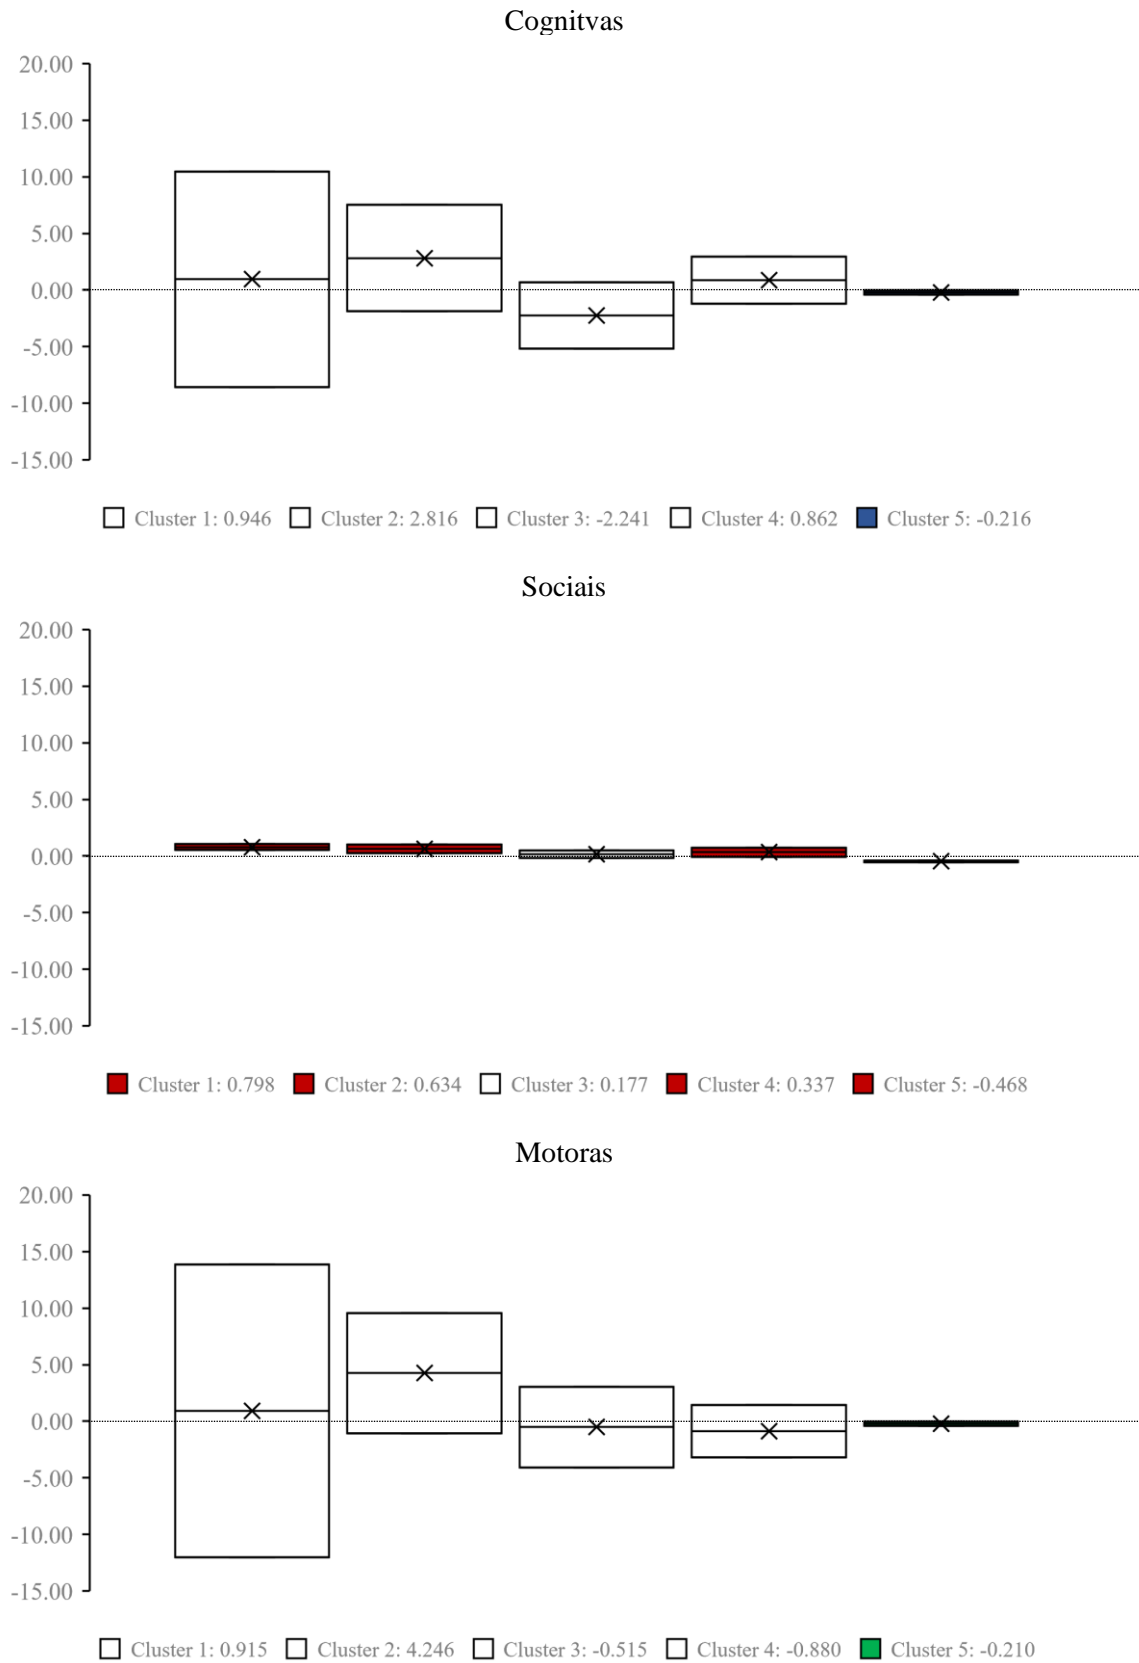
Parâmetro	Coef.	p-value	Intervalo de confiança	
Direto				
βC_1	0.6471068	***	0.1734339	1.12078
βC_2	0.3023832	ns	-0.118448	0.7232143
βC_3	-0.4752109	ns	-1.059092	0.1086698
βC_4	-0.0482296	ns	-0.5592349	0.4627757
βC_5	-0.3874729	***	-0.4510341	-0.3239116
Indireto				
βC_1	0.299274	ns	-9.06365	9.662193
βC_2	2.514236	ns	-2.16354	7.19201
βC_3	-1.76672	ns	-4.48836	0.954929
βC_4	0.910518	ns	-1.06623	2.887269
βC_5	0.171399	**	0.014638	0.328159
Total				
βC_1	0.946381	ns	-8.54514	10.4379
βC_2	2.81662	ns	-1.87981	7.513044
βC_3	-2.24193	ns	-5.16477	0.680914
βC_4	0.862289	ns	-1.2061	2.930677
βC_5	-0.21607	***	-0.40305	-0.0291

Fonte: elaborado pelo autor (2023). Nota: nível de significância ***<0.01; **<0.05 e *<0.1.

As demais classes de tamanho não possuem significância estatística. Entretanto, como os parâmetros das classes de tamanho estão modelados por meio de dummies multiplicativas, o β -convergência captura como o efeito no nível inicial das habilidades ($S_{i,t-1}$) de cada classe de tamanho é diferente do efeito no nível inicial das habilidades da classe de tamanho de referência (grupo = 5). Desta forma, os parâmetros de convergência das classes de tamanhos não são diferentes da classe de tamanho de referência, portanto, todos convergem.

A Tabela G.2 do Apêndice G apresentam os resultados completos das estimações dos modelos das classes de tamanho espaciais, bem como os testes de dependência espacial e de restrição de parâmetro para a escolha dos modelos espaciais desta seção. A Figura 32 apresenta a estimação das equações de convergência para as classes de tamanho, com as colunas representando os efeitos totais (Apêndice G – Tabela G.3) do parâmetro beta do melhor modelo econométrico espacial para cada habilidade.

Figura 32: β -convergência das habilidades na indústria por classe de tamanho



Fonte: elaborado pelo autor (2023).

A classe de tamanho de referência nas estimações foi a classe 5 e as colunas vazias representam os parâmetros dos efeitos marginais totais que não foram estatisticamente significativos em relação ao cluster de referência. Para as habilidades cognitivas e motoras, apenas as RGI da classe de tamanho 5 são estatisticamente significativas e, portanto, estão convergindo. As RGI das demais classes não são estatisticamente diferentes da classe de referência e, portanto, convergem. As habilidades sociais das RGI do cluster 1 e 2 não estão convergindo e são estatisticamente diferentes do cluster de referência. O cluster 3 também não está convergindo, porém não é estatisticamente diferente do cluster de referência. A classe de tamanho 4 não está convergindo para as habilidades sociais, porém o efeito líquido é negativo ($0.337 - 0.468 = -0.131$), indicando convergência, ou seja, o β -convergência da classe de tamanho 4 (0.337) menos o β -convergência da região de referência – classe de tamanho 5 (-0.468). As RGI da classe de tamanho 5 (referência) estão convergindo.

Analisando pelas regiões, a Figura 32 apresenta que a classe de tamanho 1 não está convergindo nas habilidades sociais, com as demais não sendo estatisticamente significativas em relação à região de referência. Desta forma, as RGI que são tradicionalmente industrializadas não estão convergindo em habilidades sociais na indústria. A mesma análise da classe de tamanho 1 serve para a classe de tamanho 2. As RGI da classe de tamanho 3 não foram estatisticamente significativas em todas as habilidades e, por isso, não são diferentes da classe de tamanho de referência.

As RGI da classe de tamanho 4 não foram estatisticamente significativas em todas as habilidades, exceto para as habilidades sociais – em que o efeito líquido é negativo, ou seja, há evidências de convergência para as habilidades sociais. Por fim, as RGI da classe de tamanho 5 (referência) convergem em todas as habilidades: sociais (-0.468), cognitivas (-0.216) e motoras (-0.210).

As análises dos clubes de convergência condicional por tamanho mostram que apesar da literatura destacar os efeitos positivos das economias de aglomeração sobre o mercado de trabalho, as evidências encontradas indicam que as regiões que pertencem às classes de tamanhos mais densos, como 1 e 2, não estão convergindo para as habilidade sociais.

Além disso, é importante observar que no cluster 1, composto por apenas 4 regiões e com a presença de São Paulo, a convergência se mostra um desafio significativo. A quantidade reduzida de regiões nesse grupo, aliada à influência de São Paulo, que apresenta características

econômicas únicas, torna complexa a obtenção de resultados convergentes. Portanto, ao analisar os clubes de convergência condicional por tamanho, é crucial considerar o número de regiões em cada grupo, pois esse fator desempenha um papel importante na dinâmica da convergência.

Uma outra observação relevante é que as RGI de um cluster não convergem para a média nacional, mas sim para a média do próprio cluster. Isso significa que a dinâmica de convergência está intrinsicamente relacionada às características específicas de cada grupo de regiões, o que pode ser influenciado por diversos fatores, como a estrutura econômica e a demanda por habilidades. Portanto, ao interpretar os resultados, é fundamental compreender que as RGI de um cluster estão em busca da convergência interna, adaptando-se às demandas locais, em vez de buscar a convergência com o panorama nacional. Essa nuance é essencial para uma análise precisa e contextualizada dos efeitos da convergência das habilidades no mercado de trabalho.


As regiões podem estar sujeitas a efeitos de convergência (ou seja, o coeficiente do nível inicial das habilidades é negativo), seja por reversão à média ou por retornos decrescentes. Os retornos das habilidades podem diminuir devido à concorrência baseada em custos e aos custos de congestionamento. Uma grande presença de indústrias em uma região pode intensificar a competição local por trabalho, encorajando os incentivos para entrada e a expansão da produção. Por exemplo, se o preço do insumo trabalho está aumentando nas regiões densas, pode haver retornos decrescentes como resultado dos custos de congestionamento (Swann, 1998, Sorenson & Audia, 2000, LaFountain, 2005, Duranton, 2007). Entretanto, é necessário um aprofundamento nessas questões para justificar as evidências encontradas nesta tese. O fato é que as evidências apontam para convergência de todos os clusters para as habilidades cognitivas e motoras, não havendo efeito diferencial para regiões mais densas. Entretanto, as evidências apontam que não há convergência para as classes de tamanhos mais densos (1 e 2) para as habilidades sociais.

4.5.2 Heterogeneidade regional para a escolaridade

O objetivo desta análise é analisar a convergência condicional da escolaridade por classe de tamanho de emprego. Os clubes de emprego industrial possibilitam verificar os efeitos das economias de aglomeração. A Figura 33 apresenta os resultados das regressões de acordo com

o fluxograma metodológico em formato de figura³³, em que as colunas representam os efeitos totais do parâmetro beta do modelo econométrico espacial SDM para os dados de escolaridade média dos trabalhadores por classe de tamanho. A Figura 33 revela que há convergência de escolaridade dos trabalhadores entre as RGI da classe de referência (5) e para a classe 3 e que as demais classes de tamanho não são estatisticamente diferentes da região de referência, portanto, elas convergem.

Figura 33: β -convergência de escolaridade na indústria por classe de tamanho



Fonte: elaborado pelo autor (2023).

As evidências apresentadas na Figura 33 apontam para a convergência da escolaridade na indústria em todas as classes. Desta forma, os resultados indicam que os trabalhadores da indústria estão se tornando mais escolarizados e mais semelhantes em termos educacionais dentro das suas classes de tamanho. Como destacado na seção 2.2, tanto pelo lado da oferta quanto pelo lado da demanda, a escolaridade média aumentou no Brasil.

4.5.3 Heterogeneidade regional para as intensidades de habilidades

O propósito dessa análise é captar os efeitos das economias de aglomeração sobre a convergência condicional por intensidade de habilidades e é também uma forma de controlar

³³ A escolha da matriz espacial e as regressões podem ser visualizadas nas Tabelas G.4, G.5 e G.6 do apêndice G.

os resultados pelo tamanho da indústria instalada nas RGI. Dessa forma, espera-se que diferentes densidades de empregos possam interferir na trajetória de crescimento por intensidade de habilidades. As Tabelas G.7 e G.8 do Apêndice G apresenta os resultados completos para as intensidades, com as estimações dos modelos dos clubes espaciais, bem como os testes de dependência espacial e de restrição de parâmetro para a escolha dos modelos espaciais desta seção. A Tabela G.9 do apêndice G apresenta os efeitos diretos, indiretos e totais.

A Figura 34 apresenta a estimação das equações de convergência para os clubes de tamanho (quartil de emprego industrial), com as colunas representando os efeitos totais (Tabela G.9 do apêndice G.) do parâmetro beta do melhor modelo econométrico espacial para cada intensidade de habilidade. O clube de referência nas estimações foi a classe de tamanho 5 e as colunas preenchidas representam os parâmetros que foram estatisticamente significativos³⁴ em relação a classe de tamanho de referência.

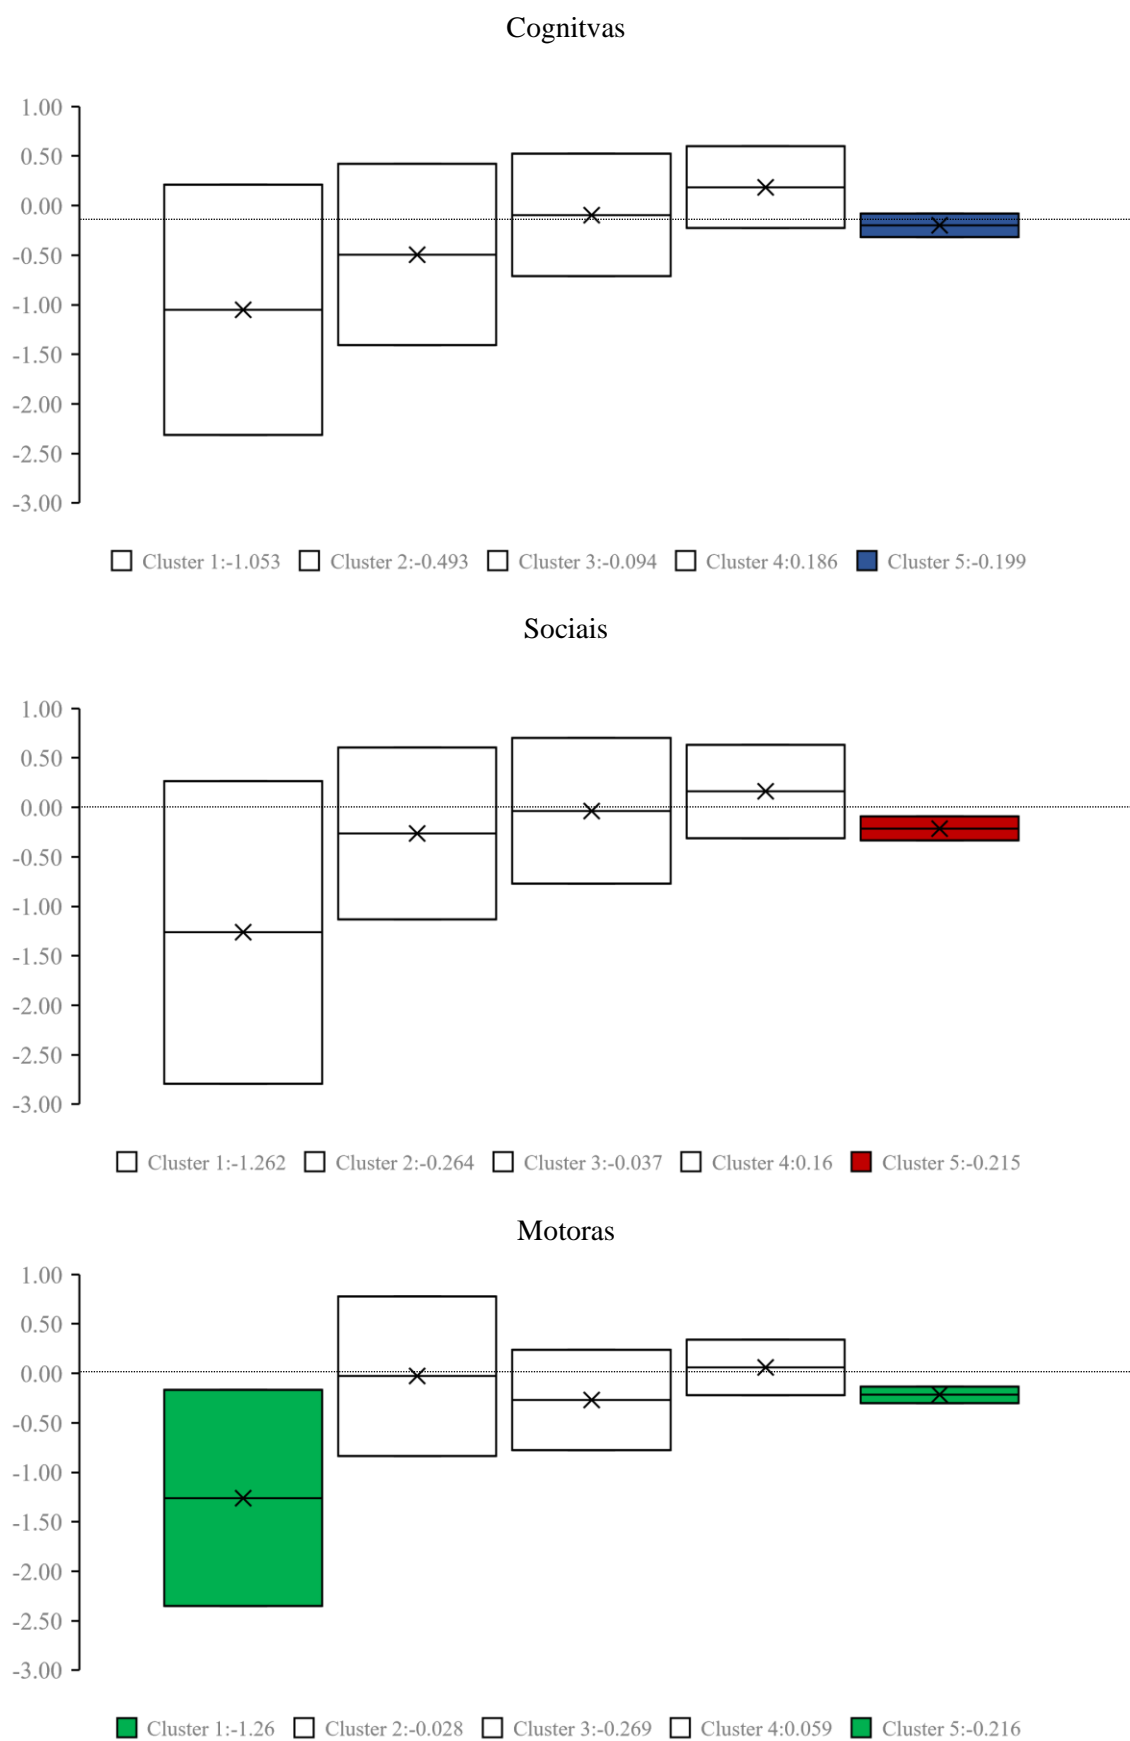
De maneira geral, todas as classes de tamanho convergem e apenas as RGI da classe 5 (referência) são estatisticamente significantes para todas as intensidades de habilidades: intensidades motoras (0.216), intensidades sociais (-0.215) e intensidades cognitivas (-0.199). Para as intensidades motoras as RGI da classe de tamanho 1 também convergem (-1.260) e são estatisticamente diferentes da classe de tamanho de referência (cluster 5).

As demais classes de tamanho não são estatisticamente diferentes da classe de tamanho de referência para os restantes das análises e, portanto, também convergem para as intensidades de habilidades. Os resultados são similares aos apresentados para a escolaridade e para as habilidades.

Dessa forma, as RGI que possuíam menores níveis obtiveram as maiores taxas de crescimento de intensidade de habilidades. Entretanto, não há efeito diferencial da convergência de intensidade de habilidades por classe de tamanho, exceto para a classe de tamanho 1 para a intensidade de habilidades motoras. Uma possível explicação é que mesmo o indicador de escolaridade sofrendo a penalidade pelas notas das habilidades das ocupações, essa penalidade não é grande o suficiente para que a dinâmica de convergência seja diferente em relação ao apresentado para o β -convergência condicional da escolaridade por classe de tamanho.

³⁴ Até 10% de significância.

Figura 34: β - convergência da intensidade de habilidade por classe de tamanho



Fonte: elaborado pelo autor (2023).

4.5.4 Comparações dos resultados de convergência para a heterogeneidade regional

A aglomeração joga um papel importante para a coordenação de capital humano, além de reter trabalhadores com níveis mais altos de escolaridade por conta da mobilidade entre as indústrias e atrair, por conta do prêmio salarial mais alto, trabalhadores qualificados para as regiões mais densas (Amarante, da Silva & do Monte, 2019). As evidências mostram que cidades altamente especializadas têm aumentado a demanda por trabalhadores altamente qualificados (Berry & Glaeser, 2005). Nesta análise, apesar das regiões mais densas estarem convergindo, a densidade de emprego não é um fator diferencial para a convergência das habilidades, escolaridade e para as intensidades de habilidades dos trabalhadores da indústria.

As RGI estão convergindo na escolaridade média em seus clubes, porém, algumas habilidades dos trabalhadores da indústria estão apresentando diferenças significativas. Por exemplo, as RGI das classes de tamanho 1 e 2, que representam as regiões tradicionalmente industrializadas, apresentam convergência na escolaridade média dos trabalhadores ocupados, porém não estão convergindo nas ocupações com habilidades sociais. Por outro lado, as RGI das classes de tamanho que representam as regiões que não são tradicionalmente industrializadas também estão convergindo na escolaridade média dos trabalhadores da indústria e também estão convergindo nas ocupações de todas as intensidades de habilidades da indústria.

Arbia (2006), que mostra fortes evidências de efeitos espaciais no modelo de convergência para as províncias italianas e as regiões europeias, sugere que as taxas de convergência estimadas usando o modelo de regressão não espacial são enviesadas, pois o efeito de transbordamento regional permite que as regiões cresçam mais rápido ou mais devagar do que o esperado. Essa descoberta confirma a hipótese do “clube de convergência”, de que regiões dentro de um país podem experimentar um clube ou clusters de convergência, em vez de um processo de convergência global. As evidências desta tese corroboram a argumentação anterior, indicando que o processo de convergência deve-se às condições comuns, socioeconômicas e/ou geográficas, resultando na presença de heterogeneidade relacionada com os subconjuntos de dados (vide os resultados para as habilidades sociais e para a intensidade de habilidades motoras), conclusão similar à encontrada em Aritenang & Chandramidi (2022).

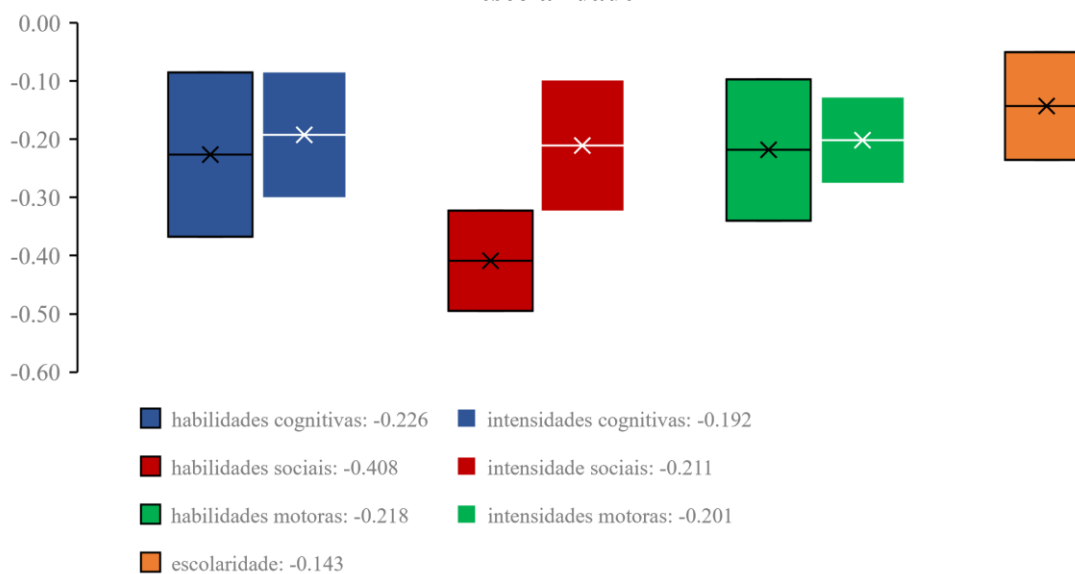
Portanto, embora não haja efeito diferencial das aglomerações sobre as análises de convergência, os resultados desta seção corroboram as evidências encontradas nas seções anteriores, em que há convergência condicional de habilidade na indústria. Os resultados

também corroboram as evidências de convergência da escolaridade e das intensidades de habilidades.

4.6 SÍNTESE DOS PRINCIPAIS RESULTADOS

O objetivo desta análise é apresentar uma síntese dos principais resultados das equações de convergência condicional global das habilidades, escolaridade e intensidades de habilidades. A Figura 35 representa os efeitos totais dos parâmetros das regressões (os resultados podem ser encontrados nas seções 4.2.1, 4.2.2 e 4.2.3) para as habilidades e escolaridade (contorno em preto) e para as intensidades das habilidades (contorno em branco). As colunas preenchidas em azul referem-se às habilidades e intensidades das habilidades cognitivas, as preenchidas em vermelho e verde referem-se às habilidades e intensidades sociais e motoras, respectivamente. A coluna preenchida em laranja refere-se à escolaridade média. Todas as colunas indicam que o efeito total do β -convergência foi estatisticamente significativo, com um p-valor de até 10%. Esses resultados estão nas Tabelas do Apêndice E. A Figura 35 apresenta evidências de convergência condicional global para ambas as métricas³⁵.

Figura 35: β - convergência das habilidades, das intensidades das habilidades e da escolaridade



Fonte: elaborado pelo autor (2023).

³⁵ Conforme o fluxograma metodológico da seção 3.9 do capítulo 3.

Ao analisar os resultados por tipo de habilidade e intensidade, não foram encontradas diferenças significativas entre as habilidades cognitivas e as intensidades das habilidades cognitivas, bem como entre as habilidades motoras e suas intensidades. No entanto, observou-se uma diferença significativa entre as habilidades sociais e sua intensidade, sendo esta última mais negativa. Em outras palavras, o parâmetro β -convergência se torna menos negativo quando a penalização das habilidades sociais é aplicada à escolaridade. Por fim, o parâmetro β -convergência condicional global para a escolaridade também é negativo.

Um indicador beta menor para as habilidades e para as intensidades das habilidades em comparação com escolaridade, ambos negativos, sugere que as habilidades estão convergindo a uma taxa mais rápida do que os níveis de escolaridade. Isso implica que a diferença nas habilidades e nas intensidades das habilidades entre os trabalhadores está diminuindo mais rapidamente em comparação com a diferença nos níveis de escolaridade.

Em termos práticos, isso pode indicar que a disparidade nas habilidades e nas intensidades entre os trabalhadores está se reduzindo mais rapidamente em comparação com a disparidade nos níveis de escolaridade, esse resultado é mais contundente para as habilidades sociais. A convergência mais lenta para os indicadores de escolaridade refletem a sua maior homogeneidade em comparação com as demais, vide os gráficos de estimativa de densidade de kernel univariada (Figuras 22, 23 e 24 da seção 4.3).

Isso sugere que, para promover a sofisticação produtiva, é fundamental continuar a focar políticas e estratégias que fortaleçam as habilidades dos trabalhadores na manufatura. Essa ênfase nas habilidades pode ser especialmente relevante em setores industriais altamente especializados que exigem níveis de habilidades maiores. No entanto, é importante considerar a interação entre habilidades e escolaridade, para obter uma compreensão abrangente da dinâmica de convergência da sofisticação produtiva.

Por outro lado, fica evidente que a interação entre habilidades e escolaridade desempenha um papel significativo na dinâmica de convergência da sofisticação. A análise separada revela que nem todas as habilidades possuem parâmetro com a mesma magnitude – o parâmetro das habilidades sociais é mais acentuado. Enquanto a análise conjunta, considerando a intensidade, auxilia no entendimento da relação dessas variáveis.

Além disso, ao considerar a dinâmica de convergência da sofisticação produtiva, é importante reconhecer a possibilidade de “*overschooling*”³⁶, indicando que a ênfase excessiva nos níveis de escolaridade pode estar em descompasso com as demandas reais do mercado de trabalho. Embora os resultados indiquem convergência mais rápida nas habilidades em comparação com os níveis de escolaridade, a análise revela uma diferença significativa nas habilidades sociais, sugerindo a presença de um “*mismatch*”³⁷ entre as habilidades sociais e a penalização aplicada à escolaridade. Essa discrepância ressalta a importância de uma abordagem abrangente para o desenvolvimento regional, em que a educação e o fortalecimento das habilidades ocupacionais devem ser cuidadosamente integrados para evitar possíveis casos de “*overschooling*” e garantir uma convergência equilibrada da sofisticação industrial.

A necessidade de políticas que não apenas promovam a educação, mas também fortaleçam as habilidades ocupacionais, é evidente. Em resumo, a análise das habilidades, escolaridade e intensidade destaca a necessidade de uma abordagem multifacetada para o desenvolvimento regional, onde a educação e o fortalecimento das habilidades ocupacionais são componentes interligados e essenciais para o alcance da convergência da sofisticação industrial.

³⁶ “*Overschooling*” refere-se a uma situação em que os indivíduos possuem níveis de escolaridade ou qualificações educacionais que excedem as demandas reais do mercado de trabalho ou as habilidades necessárias para desempenhar determinadas funções profissionais. Em outras palavras, trata-se de uma discrepância entre a quantidade de educação formal adquirida por uma pessoa e as exigências práticas do trabalho que ela realiza.

³⁷ “*Mismatch*” é um termo em inglês que pode ser traduzido para o português como “incompatibilidade” ou “desajuste”. Esse termo é utilizado em diversos contextos para descrever situações em que há uma falta de correspondência, concordância ou adequação entre diferentes elementos, características ou expectativas.

5. CONSIDERAÇÕES FINAIS

Essa tese tem como ponto central avaliar a sofisticação da produção industrial regional a partir das habilidades das ocupações envolvidas no processo produtivo. Assim, o foco é o capital humano, mas analisado a partir da sofisticação dos trabalhadores da indústria nas regiões brasileiras. A justificativa para essa temática, além da própria importância da indústria sobre o crescimento econômico, reside nas evidências de desconcentração espacial da indústria para regiões que não são tradicionalmente industrializadas. Com isso, este estudo versa sobre a dinâmica das habilidades requeridas no exercício das ocupações. Busca-se responder à seguinte pergunta: as regiões que possuíam menor sofisticação industrial, devido às habilidades requeridas nas ocupações, se tornaram mais sofisticadas? Ou seja, há convergência por habilidades na indústria de transformação?

Para responder a essa pergunta, utilizamos a estrutura teórica e empírica dos modelos de convergência espacial, com dados dos trabalhadores da indústria nas Regiões Geográficas Imediatas (RGI). Para o cálculo das notas de habilidades, utilizamos a classificação elaborada por Maciente (2013), Neves (2018) e Neves, Azzoni & Chagas (2021). Consideram-se três tipos de habilidades, cognitivas, sociais e motoras, que recebem notas que variam entre 0 e 1, conforme a intensidade requerida para o exercício da ocupação. Foram realizadas análises para a média, mediana e média do quartil mais alto das habilidades. Além disso, foram realizadas estimativas para investigar a heterogeneidade setorial e regional sobre a média das notas de habilidades. As análises foram replicadas para a escolaridade para a intensidade de habilidades.

Os resultados indicam que há convergência condicional global de habilidades na indústria, porém com diferenças significativas entre a média das habilidades, a mediana e o quartil mais alto, abrangendo as ocupações mais sofisticadas. Para a média e a mediana, a velocidade é maior para as habilidades sociais e motoras; já para as habilidades mais sofisticadas, a velocidade é maior para as habilidades cognitivas. Em geral, a indústria utiliza mais ocupações que requerem habilidades sociais em relação a habilidades cognitivas e motoras. As evidências também apontam que tanto a escolaridade quanto a intensidade de habilidades da estão convergindo também. Apesar das evidências sugerirem que esses dados são positivos, em termos de apontar para uma redução das disparidades regionais, há de se ressaltar o contexto de desindustrialização e de alterações do modo de produção. Desta forma, os empregos que permanecem ou que são contratados pela indústria estão em ocupações que requerem cada vez

menos habilidades motoras, que é a base das habilidades das ocupações no setor. Essas evidências podem ser justificadas pelo aumento da dependência estrutural da indústria por bens para consumo intermediário e finais importados, bem como pelo progresso tecnológico poupador de mão de obra, sobretudo em ocupações que requerem habilidades motoras. Os testes de robustez corroboram as evidências encontradas.

Além disso, quando se analisou a convergência condicional global por grupos de indústrias, os resultados foram heterogêneos ao tipo de indústria, mesmo havendo convergência para todos os grupos e habilidades. Os resultados deste estudo revelam insights importantes sobre as dinâmicas das habilidades na indústria brasileira e suas implicações econômicas. Observa-se que as habilidades requeridas variam entre diferentes setores, com ênfase em habilidades sociais na agroindústria e habilidades cognitivas e motoras nos demais segmentos da indústria. Além disso, as indústrias intensivas em capital utilizam mais trabalhadores com habilidades cognitivas e sociais, enquanto as intensivas em trabalho enfatizam as habilidades motoras.

Essas descobertas são relevantes, pois indicam que a composição da força de trabalho industrial e a sofisticação das ocupações estão relacionadas ao tipo de indústria presente nas regiões. Isso, por sua vez, pode afetar o investimento em P&D, os salários e a atividade econômica local e regional se houver complementariedade entre habilidades e P&D.

Além das diferenças nas habilidades, também se observam variações na convergência da escolaridade entre segmentos da indústria. Nota-se que, embora haja convergência na escolaridade dos trabalhadores, a taxa de convergência é maior nos setores não agroindustriais e naqueles intensivos em trabalho, em comparação com a agroindústria e a indústria intensiva em capital, respectivamente. Esses resultados indicam que a composição educacional da força de trabalho industrial está se tornando mais homogênea ao longo do tempo, mas essa convergência é mais pronunciada em determinados setores. Isso pode ter implicações significativas para a capacidade de inovação, produtividade e competitividade nas regiões onde estão instaladas estas indústrias.

Para as intensidades de habilidades, as evidências da tese indicam velocidades maiores para todas as intensidades de habilidades para a agroindústria, em comparação com os demais segmentos. Os parâmetros das indústrias intensivas em capital e intensivas em trabalho também apresentam variações. Na indústria intensiva em trabalho, a convergência é mais acentuada para

habilidades cognitivas e motoras, enquanto na indústria intensiva em capital, o destaque recai sobre as habilidades sociais.

O espaço joga um papel importante, uma vez que as regiões podem apresentar importantes diferenças institucionais e estruturais em suas escalas econômicas, mercado de trabalho e infraestrutura, que impactam de forma heterogênea a convergência das habilidades. Por essas e outras razões mencionadas ao longo da tese, realizou-se análise de heterogeneidade (clubes) de convergência das habilidades.

Os resultados da heterogeneidade espacial mostram evidências de que as regiões menos industrializadas estão convergindo dentro das suas classes de tamanho com velocidades maiores para as habilidades sociais, seguidas das cognitivas e das motoras. Entretanto, as regiões mais industrializadas não estão convergindo dentro das suas classes de tamanho para as habilidades sociais. Quando se comparam as diferenças entre as classes de tamanho, percebe-se que não existem diferenças entre regiões menos e mais industrializadas, exceto para as habilidades sociais. O mesmo padrão é observado para a escolaridade e para a intensidade de habilidades. Uma conclusão importante deste estudo é que um conhecimento das distintas reações das diferentes classes de tamanho é necessário para que os formuladores de políticas compreendam melhor quais tipos de políticas de desenvolvimento têm maior probabilidade de apoiar as indústrias locais. Além disso, os efeitos espaciais dos modelos econométricos reforçam que as políticas de desenvolvimento regional têm mais importância do que políticas isoladas geograficamente, por conta dos efeitos dos *spillovers*.

Essa tese ainda explorou a convergência da escolaridade dos trabalhadores. A falta de escolaridade poderia restringir as contratações em ocupações que requerem maiores níveis de habilidade. Os resultados mostram que há convergência de escolaridade entre as RGI de cada classe de tamanho. Essas evidências trazem considerações importantes, pois espera-se que a escolaridade média aumente no longo prazo, porém as habilidades dos trabalhadores da indústria dependem de diversos fatores (políticos, econômicos e da própria modernização da indústria).

Portanto, as evidências desta tese indicam um aumento no nível educacional dos trabalhadores da indústria e uma mudança mais significativas nas ocupações com habilidades sociais, em detrimento das habilidades motoras. Os resultados fornecem informações cruciais sobre as tendências das habilidades requeridas na indústria ao longo do tempo. O aumento do nível

educacional dos trabalhadores e a ênfase crescente nas habilidades sociais indicam uma mudança na dinâmica do mercado de trabalho industrial no Brasil. Essas descobertas podem oferecer insights sobre o futuro da indústria e como ela está se adaptando às mudanças tecnológicas e econômicas globais. Isso é relevante tanto para as indústrias que precisam ajustar suas estratégias de recrutamento e treinamento de mão-de-obra como para os governos que elaboram políticas de desenvolvimento e de competitividade industrial. Além disso, as mudanças nas habilidades exigidas na indústria também têm implicações econômicas para as regiões que dependem da indústria como fonte de empregos e crescimento. Compreender essas mudanças ajuda na formulação de políticas de crescimento e desenvolvimento regional.

Além disso, ao considerar a dinâmica de convergência da sofisticação produtiva, destaca-se a relevância de reconhecer a possibilidade de *overschooling* como um elemento crítico. A ênfase excessiva nos níveis de escolaridade nas análises, embora indique uma convergência mais rápida nas habilidades em comparação com os níveis educacionais, revela uma diferença significativa, principalmente nas habilidades sociais. Esta disparidade aponta para um *mismatch* entre as habilidades e a valorização atribuída à escolaridade, sublinhando a necessidade de uma abordagem abrangente para o desenvolvimento regional. Integrar cuidadosamente a educação e o fortalecimento das habilidades ocupacionais é imperativo para evitar possíveis casos de *overschooling* e garantir uma convergência equilibrada da sofisticação industrial nas regiões brasileiras.

De qualquer forma, os resultados mencionados oferecem uma visão abrangente das mudanças nas habilidades da força de trabalho industrial, com implicações para a educação, as políticas de treinamento, o futuro da indústria no Brasil e o desenvolvimento econômico regional. A contribuição principal desta tese está em olhar para a sofisticação das ocupações da indústria como uma nova forma de avaliar a dinâmica do mercado de trabalho e avaliar a complexidade da indústria instalada nas regiões brasileiras para além dos níveis de escolaridade.

Por fim, a dinâmica da indústria e do mercado de trabalho é moldada por uma série de fatores em constante mudança. Algumas questões permanecem em aberto, aguardando investigação adicional: como as mudanças tecnológicas em curso afetarão as habilidades na indústria regional?; Quais medidas políticas podem ser implementadas para preparar os trabalhadores para as mudanças nas habilidades exigidas pela indústria?; Como as instituições de ensino, governos e empresas podem colaborar de maneira eficaz nesse processo?; Como as regiões industriais podem se tornar mais resistentes a choques econômicos e tecnológicos?; Quais

estratégias de diversificação econômica podem ser adotadas para garantir o crescimento sustentável? À medida que a ciência e a economia continuam a se entrelaçar, há um vasto terreno de pesquisa a ser explorado. A complexidade do mundo industrial, das habilidades e das escolaridades dos trabalhadores não cessa de surpreender a todos, e é por meio do diálogo, pesquisa e inovação contínuos que se esperam desvendar esses intrincados desafios.

REFERÊNCIAS

Acemoglu, D. & Autor, D. (2011). Skills, tasks and technologies: Implications for employment and earnings. *In: Handbook of Labor Economics*, 4.

Adamczyk, W. B. (2021). Ensaio sobre as tecnologias de automação no mercado de trabalho brasileiro. Tese (*Doutorado*) – Pontifícia Universidade Católica do Rio Grande do Sul, Porto Alegre.

Aksoy, T., Taştan, H., & Kama, Ö. (2019). Revisiting income convergence in Turkey: Are there convergence clubs? *Growth and Change*, 50(3), 1185-1217.

Almeida, E. (2012). *Econometria espacial*. Campinas–SP. Alínea, 31.

Amarante, P. A., da Silva, M. V. B., & do Monte, P. A. (2019). Does the spatial density of employment stimulate inter-firm worker mobility? An analysis of Brazilian municipalities. *The annals of regional science*, 63(1), 85-115.

Anselin, L. (1988). *Spatial econometrics: methods and models*. Boston: Kluwer Academic.

Anselin, L. (2005). *Exploring spatial data with GeoDaTM: A workbook* (pp. 165–223). Center for Spatially Integrated Social Science.

Anselin, L., & Bera, A. K. (1998). Introduction to spatial econometrics. *Handbook of applied economic statistics*, 237(5).

Anselin, L., & Florax, R. J. (1995). New directions in spatial econometrics: Introduction. In *New directions in spatial econometrics* (pp. 3-18). Berlin, Heidelberg: Springer Berlin Heidelberg.

Anselin, L., & Rey, S. (1991). Properties of tests for spatial dependence in linear regression models. *Geographical analysis*, 23(2), 112-131.

Anselin, L., Bera, A. K., Florax, R., & Yoon, M. J. (1996). Simple diagnostic tests for spatial dependence. *Regional science and urban economics*, 26(1), 77-104.

Araújo, V. D. C. (2014). Dimensão local da inovação no Brasil: determinantes e efeitos de proximidade (*Doctoral dissertation*). Universidade de São Paulo.

Arbia, G. (2006). *Spatial econometrics: statistical foundations and applications to regional convergence*. Springer Science & Business Media.

Arbia, G., & Piras, G. (2005). Convergence in per-capita GDP across European regions using panel data models extended to spatial autocorrelation effects. (*Discussion Paper*).

Arbia, G., Basile, R., & Piras, G. (2005). Using spatial panel data in modelling regional growth and convergence. (*Discussion Paper*).

Arbia, G., Le Gallo, J., & Piras, G. (2008). Does evidence on regional economic convergence depend on the estimation strategy? Outcomes from analysis of a set of NUTS2 EU regions. *Spatial economic analysis*, 3(2), 209-224.

Aritenang, A. F., & Chandramidi, A. N. (2020). The impact of special economic zones and government intervention on firm productivity: The case of Batam. *Indonesia. Bulletin of Indonesian Economic Studies*, 56(2), 225-249.

- Arrow, K. J. (1971). The economic implications of learning by doing. *In: Readings in the Theory of Growth*. Palgrave Macmillan, London, 131-149.
- Asheim, B. T., Boschma, R., & Cooke, P. (2011). Constructing regional advantage: Platform policies based on related variety and differentiated knowledge bases. *Regional Studies*, 45(7):893–904.
- Autor, D. (2015). Why Are There Still So Many Jobs? The History and Future of Workplace Automation. *Journal of Economic Perspectives*, v. 29, n. 3, p. 3-30.
- Azambuja, L. R., & Mocelin, D. G. (2016). A Demanda de Trabalho das Empresas de Serviços TIC no Brasil, 2006 a 2013. *Revista de Estudos Interdisciplinares*, 18(1).
- Azzoni, C. R., & Castro, G. H. L. (2023). Economic crises and regional disparities in Brazil in the XXI Century. São Paulo: Nereus. (*Texto para Discussão*, 01-2023).
- Azzoni, C. R., & Ferreira, D. A. (1998). Competitividad regional y reconcentración industrial: el futuro de las desigualdades regionales en Brasil. *Revista Latinoamericana de Estudios Urbano Regionales*, 24(73), 81-111.
- Backman, M. (2014). Human capital in firms and regions: Impact on firm productivity. *Papers in regional science*, 93(3), 557-575.
- Barro, R. J. (1991). Economic growth in a cross section of countries. *The quarterly journal of economics*, 106 (2):407-443.
- Barro, R. J. (2000). Inequality and Growth in a Panel of Countries, *Journal of Economic Growth*, 5, 5–3.
- Barro, R. J., & Sala-I-Martin, X. (1992). Convergence. *Journal of political Economy*, 100(2): 223-251.
- Barro, R. J., Sala-I-Martin, X., Blanchard, O. J., & Hall, R. E. (1991). Convergence across states and regions. *Brookings papers on economic activity*, 107-182.
- Barufi, A. M. B., Haddad, E. A., & Nijkamp, P. (2016). Industrial scope of agglomeration economies in brazil. *The Annals of Regional Science*, 56(3):707–755.
- Bassanini, A., & Scarpetta, S. (2002). Does human capital matter for growth in OECD countries? A pooled mean group approach. *Economics letters*, 74(3): 399-405.
- Baumol, W.J. (1986). Productivity growth, convergence, and welfare: what the long-run data show. *The american economic review*, 1072-1085.
- Beaudry, C. & Schiffauerova, A. (2009). Who’s right, Marshall or Jacobs? The localization versus urbanization debate. *Research Policy*, 38: 318–337.
- Beaudry, P., Doms, M., & Lewis, E. (2010). Should the personal computer be considered a technological revolution? evidence from us metropolitan areas. *Journal of political Economy*, 118(5):988–1036.
- Becker, G. S. (1964). *Human capital: A theoretical and empirical analysis, with special reference to education*. University of Chicago press.
- Benhabib, J. & Spiegel, M. M. (1994). The role of human capital in economic development: evidence from aggregate cross-country data. *Journal of Monetary Economics*, 34(2):143-173.

- Bernard, A. B., Smeets, V., & Warzynski, F. (2017). Rethinking deindustrialization. *Economic Policy*, 32(89): 5-38.
- Bernardelli, L. V., de Castro, G. H. L., Gobi, J. R., Michellon, E., & Vieira Filho, J. E. R. (2020). Formalidade do mercado de trabalho e produção agrícola no Brasil (No. 2561). *Texto para Discussão*.
- Berry, C. R. & Glaeser, E. L. (2005). The divergence of human capital levels across cities. *Papers in regional science*, 84(3):407–444.
- Binelli, C., & Menezes-Filho, N. (2019). Why Brazil fell behind in college education? *Economics of Education Review*, 72, 80-106.
- Blinder, A. S. & Krueger, A. B. (2013). Alternative measures of offshorability: a survey approach. *Journal of Labor Economics*, 31(S1): S97–S128.
- Boschma, R. & Iammarino, S. (2009). Related variety, trade linkages, and regional growth in Italy. *Economic geography*, 85(3):289–311.
- Brando, N. (2017). Between equality and freedom of choice: Educational opportunities for the least advantaged. *International Journal of Educational Development*, 53, 71-79.
- Brasil (2017). *Divisão regional do Brasil em regiões geográficas imediatas e regiões geográficas intermediárias IBGE*, Coordenação de Geografia. - Rio de Janeiro: 82.
- Brasil (2018). IBGE - Instituto Brasileiro de Geografia e Estatística. *Pesquisa Industrial Anual: Empresa*. Rio de Janeiro: IBGE.
- Brasil (2018b). MDIC - *Ministério do Desenvolvimento, da Indústria e Comércio Exterior* Anuário Estatístico. Rio de Janeiro: Dez 2018.
- Brasil (2023e). PNAD Continua – Pesquisa Nacional por Amostra de Domicílios Contínua. Educação 2022. Rio de Janeiro: IBGE. Disponível em <https://biblioteca.ibge.gov.br/visualizacao/livros/liv102002_informativo.pdf>.
- Brasil. (2018a). Ministério do Trabalho e Emprego. Programa de Disseminação das Estatísticas do Trabalho. *Relação Anual de Informações Sociais (RAIS)* Brasília, DF.
- Brasil. (2023a). CONCLA - *Comissão Nacional de Classificação*. Rio de Janeiro: IBGE. Disponível em: <http://surl.li/hmyxa>.
- Brasil. (2023b). IBGE - Instituto Brasileiro de Geografia e Estatística. *Agência IBGE Notícias*. Rio de Janeiro: IBGE. Disponível em: <http://surl.li/hmzfp>
- Brasil. (2023c). Lei nº 13.303, de 30 de junho de 2016. Dispõe sobre o estatuto jurídico da empresa pública, da sociedade de economia mista e de suas subsidiárias, no âmbito da União, dos Estados, do Distrito Federal e dos Municípios. Diário Oficial da União, Brasília, DF, 30 jun. 2016.
- Brasil. (2023d). Ministério do Trabalho e Emprego. Programa de Disseminação das Estatísticas do Trabalho. *Relação Anual de Informações Sociais (RAIS)* Brasília, DF.
- Brene, P. R. A., Sesso Filho, U. A., Rodrigues, R. L., & Moretto, A. C. (2014). Mudança estrutural e dualismo no Brasil: Uma análise insumo-produto para os anos 2000 e 2007. *Revista Capital Científico-Eletrônica*, 12(4), 29-46.

- Breschi, S., & Lissoni, F. (2001). Knowledge spillovers and local innovation systems: a critical survey. *Industrial and corporate change*, 10(4), 975-1005.
- Brynjolfsson, E. & McAfee, A. (2014). *The second machine age: Work, progress, and prosperity in a time of brilliant technologies*. WW Norton & Company.
- Bustos, P., Caprettini, B., & Ponticelli, J. (2016). Agricultural productivity and structural transformation: Evidence from Brazil. *American Economic Review*, 106(6):1320–65.
- Cadman, C., & Brewer, J. (2001). Emotional intelligence: a vital prerequisite for recruitment in nursing. *Journal of nursing management*, 9(6):321-324.
- Cantore, N., Clara, M., Lavopa, A. & Soare, C. (2017). Manufacturing as an engine of growth: Which is the best fuel? *Structural Change and Economic Dynamics*, 42:56-66.
- Caragliu, A., de Dominicis, L., & de Groot, H. L. (2016). Both Marshall and Jacobs were right! *Economic Geography*, 92(1):87–111.
- Carcanholo, H. & Porsse, A. A. (2016). As leis de Kaldor no espaço: uma análise para os municípios brasileiros com modelos de regressões geograficamente ponderadas. *Revista Econômica do Nordeste*, 47(4): 123-136.
- Cardozo, D. P., & Cunha, M. D. S. (2019). Salários e emprego no mercado de trabalho formal agrícola brasileiro. *Revista de Política Agrícola*, 27(3): 17-32.
- Carnoy, M., Froumin, I., Loyalka, P. K., & Tilak, J. B. (2014). The concept of public goods, the state, and higher education finance: a view from the BRICs. *Higher Education*, 68: 359-378.
- Cass, D. (1965). Optimum growth in an aggregative model of capital accumulation. *Review of Economics Studies*, 32: 233-240.
- Castro, G. H. L., & Azzoni, C. R. (2021). Sofisticação da demanda por mão de obra nas regiões do estado do Paraná. *Revista Paranaense de Desenvolvimento*, 42(140).
- Castro, G. H. L., Brene, P. R. A., Sesso Filho, U. A., Luquini, R. H., & Bernardelli, L. V. (2017). Multiplicadores de importação dos produtos da economia brasileira: uma análise insumo-produto para os anos 2000 e 2009. *Revista Brasileira de Estudos Regionais e Urbanos*, 11(1): 20-37.
- Castro, G. H., de Barros, P. H., & Menezes-Filho, N. (2021). The human capital effect on productivity and the agricultural frontier expansion: evidence from Brazil. *Anais*.
- Chang, C. F., & Lin, C. S. (2017). The role of human capital in manufacturing plant growth: Evidence from Taiwan. *Pacific Economic Review*, 22(4): 554-584.
- Chang, C. F., Wang, P., & Liu, J. T. (2016). Knowledge spillovers, human capital and productivity. *Journal of Macroeconomics*, 47, 214-232.
- Chenery, H. B. & Watanabe, T. (1958). International comparisons of the structure of production. *Econometrica. Journal of the Econometric Society*, 487-521.
- Chenery, H. B. (1960). Patterns of industrial growth. *The American economic review*, 50(4): 624-654.
- Combes, P.-P. & Gobillon, L. (2015). The empirics of agglomeration economies. In *Handbook of regional and urban economics*, volume 5, pages 247–348. Elsevier.

- Combes, P.P., Duranton, G., Gobillon, L., & Roux, S. (2010). *Estimating Agglomeration Economies with History, Geology, and Worker Effects*. University of Chicago Press.
- Cornwall, J. (1976). Diffusion, convergence and Kaldor's laws. *The Economic Journal*, 86(342): 307-314.
- Corrado, L., & Fingleton, B. (2012). Where is the economics in spatial econometrics? *Journal of Regional Science*, 52(2): 210-239.
- Coutinho, L., Laplane, M., & Hiratuka, C. (2003). *Internacionalização e desenvolvimento da indústria no Brasil*. São Paulo. Ed: UNESP.
- Cuaresma, J. C., Doppelhofer, G. & Feldkircher, M. (2014). The determinants of economic growth in European regions. *Regional Studies*, Londres, 48(1): 44-67.
- Cui, W., & Tang, J. (2023). Innovation convergence clubs and their driving factors within urban agglomeration. *Economic Modelling*, 121, 106199.
- Da Silva Catela, E. Y., Porcile, G., & Gonçalves, F. (2010). Brazilian municipalities: agglomeration economies and development levels in 1997 and 2007. *Cepal Review*, 101:141-156.
- Da Silva Filho, L. A. (2016). Labour market and turnover in the industrial employment in the Brazilian Northeast region. *Investigación económica*, 75(295): 203-230.
- Da Silva, G. D., Gonçalves, E., & de Araújo, I. F. (2020). Related variety and employment growth: A spatial dynamic model for Brazilian microregions. *Regional Science Policy & Practice*, 12(1): 105-123.
- Daniel, B. (2015). Big Data and analytics in higher education: Opportunities and challenges. *British journal of educational technology*, 46(5): 904-920.
- David, H. & Dorn, D. (2013). The growth of low-skill service jobs and the polarization of the us labor market. *American economic review*, 103(5): 1553-97.
- Dawid, H., Gemkow, S., Harting, P., & Neugart, M. (2013). Labor market integration policies and the convergence of regions: the role of skills and technology diffusion. In: *The Two Sides of Innovation*. Springer, 67-186.
- De Almeida, E. T. & de Moraes Rocha, R. (2018). Labor pooling as an agglomeration factor: Evidence from the Brazilian northeast in the 2002-2014 period. *Economia*, 19(2): 236-250.
- De Araújo, I. F., Gonçalves, E., & Almeida, E. (2019). Effects of dynamic and spatial externalities on local growth: Evidence from Brazil. *Papers in Regional Science*, 98(2): 1239-12.
- Delgado, M., Porter, M. E., & Stern, S. (2014). Clusters, convergence, and economic performance. *Research policy*, 43(10): 1785-1799.
- Di Pietro, G., & Urwin, P. (2006). Education and skills mismatch in the Italian graduate labour market. *Applied Economics*, 38(1): 79-93.
- Diniz, C. C. (1993). Desenvolvimento poligonal no Brasil: nem desconcentração nem contínua polarização, *Nova Economia*, 3(1).
- Diniz, C. C., & Mendes, P. S. (2021). Tendências regionais da indústria brasileira no século XXI (No. 2640). *Texto para discussão*.

- Diop, S. (2018). Convergence and spillover effects in Africa: a spatial panel data approach. *Journal of African Economies*, 27(3): 274-284.
- Donald, W. E., Baruch, Y., & Ashleigh, M. (2019). The undergraduate self-perception of employability: Human capital, careers advice, and career ownership. *Studies in Higher Education*, 44(4): 599-614.
- Du, X., & Xie, Z. (2020). Occurrence of turning point on environmental Kuznets curve in the process of (de) industrialization. *Structural Change and Economic Dynamics*, 53: 359-369.
- Duranton, G. & Puga, D. (2004). Micro-foundations of urban agglomeration economies. In *Handbook of regional and urban economics*, v. 4, p. 2063–2117. Elsevier.
- Duranton, G. & Puga, D. (2005). From sectoral to functional urban specialisation. *Journal of urban Economics*, 57(2): 343–370.
- Duranton, G. (2007). Urban evolutions: The fast, the slow, and the still. *American Economic Review*, 97(1): 197-221.
- Eeckhout, J., Pinheiro, R., & Schmidheiny, K. (2014). Spatial sorting. *Journal of Political Economy*, 122(3): 554–620.
- Elhorst, J. P. (2010). Applied spatial econometrics: raising the bar. *Spatial economic analysis*, 5(1): 9-28.
- Ellery Jr., & Ferreira, P. (1996). Convergência entre a renda per capita dos estados brasileiros. *Revista de Econometria*, 16(1): 83-103.
- Ertur, C., Le Gallo, J., & Baumont, C. (2006). The European regional convergence process, 1980-1995: Do spatial regimes and spatial dependence matter? *International Regional Science Review*, 29(1): 3-34.
- Esposti, R., & Bussoletti, S. (2008). Impact of Objective 1 funds on regional growth convergence in the European Union: A panel-data approach. *Regional Studies*, 42(2): 159-173.
- Fally, T., Paillacar, R., & Terra, C. (2010). Economic geography and wages in Brazil: Evidence from micro-data. *Journal of Development Economics*, 91(1): 155–168.
- Favro, J., & Alves, A. F. (2020). Agroindústria: delimitação conceitual para a economia brasileira. *Revista de Política Agrícola*, 29(3): 1-19
- Felipe, J., Mehta, A., & Rhee, C. (2018). Manufacturing matters... but it's the jobs that count. *Cambridge Journal of Economics*, 43(1): 139-168.
- Firpo, S., Fortin, N. M., & Lemieux, T. (2011). Occupational tasks and changes in the wage structure. *IZA Discussion Paper*, 5542.
- Fischer, M. M., & Wang, J. (2011). *Spatial data analysis: models, methods and techniques*. Springer Science & Business Media.
- Frank, A. G., Dalenogare, L. S., & Ayala, N. F. (2019). Industry 4.0 technologies: Implementation patterns in manufacturing companies. *International Journal of Production Economics*, 210: 15-26.

- Frenken, K. & Boschma, R. A. (2007). A theoretical framework for evolutionary economic geography: industrial dynamics and urban growth as a branching process. *Journal of economic geography*, 7(5): 635–649.
- Frenken, K., Van Oort, F., & Verburg, T. (2007). Related variety, unrelated variety and regional economic growth. *Regional studies*, 41(5): 685–697.
- Frey, C. & Osborne, M. (2017). The Future of Employment: how susceptible are jobs to computerisation? *Technological forecasting and social change*, 114: 254–280.
- Gabriel, L. F. & De Santana Ribeiro, L. (2019). Economic growth and manufacturing: An analysis using Panel VAR and intersectoral linkages. *Structural Change and Economic Dynamics*, 49: 43–61.
- Gala, P. (2007). Dois padrões de política cambial: América latina e sudeste asiático. *Economia e Sociedade*, 16(01): 65–69.
- Galetti, J. R. B., Tessarin, M. S., & Morceiro, P. C. (2021). Skill relatedness, structural change and heterogeneous regions: evidence from a developing country. *Papers in Regional Science*.
- Galliano, D., Magrini, M.-B., & Triboulet, P. (2015). Marshall’s versus jacobs’ externalities in firm innovation performance: The case of french industry. *Regional studies*, 49(11):1840–1858.
- Glaeser, E. L. & Gottlieb, J. D. (2008). *The economics of place-making policies*. Technical report, National Bureau of Economic Research.
- Glaeser, E. L., & Gottlieb, J. D. (2009). The wealth of cities: Agglomeration economies and spatial equilibrium in the United States. *Journal of economic literature*, 47(4): 983–1028.
- Glaeser, E. L., Resseger, M., & Tobio, K. (2009). Inequality in cities. *Journal of Regional Science*, 49(4): 617–646.
- Goldin, C. & Katz, L. F. (1998). The Origins of Technology-Skill Complementarity. *The Quarterly Journal of Economics*, 113(3): 693–732.
- Gonçalves, E. (2007). O padrão espacial da atividade inovadora brasileira: uma análise exploratória. *Estudos Econômicos*, 37: 405–433.
- Gordon, J. L., & Gramkow, C. (2011). As características estruturais da inserção externa brasileira e suas principais implicações-2000/2010. *Cadernos do Desenvolvimento*, 6(9): 93–118.
- Griffith, R., Redding, S., & Reenen, J. V. (2004). Mapping the two faces of R&D: Productivity growth in a panel of OECD industries. *Review of economics and statistics*, 86(4): 883–895.
- Groot, S. P., de Groot, H. L., & Smit, M. J. (2014). Regional wage differences in the netherlands: Micro evidence on agglomeration externalities. *Journal of Regional Science*, 54(3): 503–523.
- Gu, J. (2012). Harmonious expansion of China’s higher education: A new growth pattern. *Higher Education*, 63: 513–528.

- Guastella, G., & Timpano, F. (2016). Knowledge, innovation, agglomeration and regional convergence in the EU: motivating place-based regional intervention. *Review of Regional Research*, 36: 121-143.
- Guimarães, P. M., & Almeida, E. (2017). A análise de convergência de renda no Brasil e o problema de escala espacial. *Ensaio FEE*, 37(4): 899-924.
- Guo, D., Dall’Erba, S. & Gallo, J. L. (2013). The leading role of manufacturing in China’s regional economic growth: A spatial econometric approach of Kaldor’s laws. *International Regional Science Review*, 36(2): 139-166.
- Hanushek, E. A., & Woessmann, L. (2011). The economics of international differences in educational achievement. *Handbook of the Economics of Education*, 3: 89-200.
- Haraguchi, N., Cheng, C. F. C. & Smeets, E. (2017). The importance of manufacturing in economic development: Has this changed? *World Development*, 93: 293-315.
- Hembram, S., Mukherjee, S., & Haldar, S. K. (2020). Regional convergence of social and economic development in the districts of West Bengal, India: Do clubs exist? Does space matter? An empirical analysis using DLHS I–IV and NFHS IV data. *Journal of Social and Economic Development*, 22: 58-90.
- Hendry, D. F. (2000). Epilogue: The Success of General-to-specific Model Selection, Chapter 20 in D. F. Hendry (ed.) *Econometrics: Alchemy or Science? Essays in Econometric Methodology*, Oxford University Press, Oxford, New Edition, 467—490.
- Hoenicke, N. F. (2007). O Distrito Industrial de Joinville/SC (1975-2007): análise crítica e propositiva (Doctoral dissertation, Universidade de São Paulo).
- Ioannides, Y. M., Overman, H. G., Rossi-Hansberg, E., & Schmidheiny, K. (2008). The effect of information and communication technologies on urban structure. *Economic Policy*, 23(54): 202–242.
- Islam, N. (2003). What have we learnt from the convergence debate? *Journal of economic surveys*, 17(3).
- Kagermann, H., Wahlster, W., & Helbig, J. (2013). Recommendations for Implementing the Strategic Initiative INDUSTRIE 4.0 - Final Report of the industrie 4.0 Working Group. In *Industrie*. Frankfurt.
- Kaldor, N. (1957). A model of economic growth. *The economic journal*, 67(268): 591-624.
- Kaldor, N. (1966). *Causes of the slow rate of economic growth of the United Kingdom: an inaugural lecture*. Cambridge University Press.
- Kaldor, N. (1967). Problems of industrialization in underdeveloped countries. *Strategic Factors in Economic Development*, 53-72.
- Kaldor, N. (1968). Productivity and growth in manufacturing industry: a reply. *Economica*, 35(140): 385-391.
- Kannebley JR., S.; Prince, D. de & Scarpelli, M. C. (2011). Histerese e o comércio exterior de produtos industrializados brasileiros. *Pesquisa e Planejamento Econômico (PPE)*, 41(03): 397-432.

- Kautz, T., Heckman, J. J., Diris, R., Ter Weel, B., & Borghans, L. (2014). Fostering and measuring skills: Improving cognitive and non-cognitive skills to promote lifetime success, *Working Papers* 20749, National Bureau of Economic Research.
- Kemeny, T. & Storper, M. (2015). Is specialization good for regional economic development? *Regional Studies*, 49(6): 1003–1018.
- Koopmans, T. C. (1965). On the concept of optimal economic growth. In *The Econometric Approach to Development Planning*, Amsterdam: North Holland.
- Krugman, P. R. (1997). *The age of diminished expectations: US economic policy in the 1990s*. MIT press.
- Kubara, M., & Kopczewska, K. (2023). Akaike information criterion in choosing the optimal k-nearest neighbours of the spatial weight matrix. *Spatial Economic Analysis*, 1-19.
- LaFountain, C. (2005). Where do firms locate? Testing competing models of agglomeration. *Journal of urban economics*, 58(2): 338-366.
- Le Gallo, J., & Dall’Erba, S. (2006). Evaluating the temporal and spatial heterogeneity of the European convergence process, 1980–1999. *Journal of Regional Science*, 46(2): 269-288.
- Lee, J. W. (2005). Human capital and productivity for Korea's sustained economic growth. *Journal of Asian Economics*, 16(4): 663-687.
- LePine, J. A., Colquitt, J. A., & Erez, A. (2006). Adaptability to changing task contexts: Effects of general cognitive ability, conscientiousness, and openness to experience. *Personnel psychology*, 53(3): 563-593.
- LeSage, J. P., & Fischer, M. M. (2008). Spatial growth regressions: model specification, estimation and interpretation. *Spatial Economic Analysis*, 3(3): 275-304.
- Lesage, J., & Pace, R. K. (2009). *Introduction to spatial econometrics*. Chapman and Hall/CRC.
- Lin, J. (2011). Technological adaptation, cities, and new work. *Review of Economics and Statistics*, 93(2): 554–574.
- Lisboa, M., Menezes Filho, N., & Schor, A. (2010). The effects of trade liberalization on productivity growth in Brazil: competition or technology? *Revista Brasileira de Economia* 64.3: 277-289.
- Longo, F., Nicoletti, L. & Padovano, A. (2017). Smart operators in industry 4.0: a human-centered approach to enhance operators' capabilities and competencies within the new smart factory context. *Computers & Industrial Engineering*, 113: 144–159.
- Lucas Jr, R. E. (1988). On the mechanics of economic development. *Journal of monetary economics*, 22(1): 3–42.
- Maciente, A. N. (2013). *The determinants of agglomeration in Brazil: input-output, labor and knowledge externalities*. University of Illinois at Urbana-Champaign.
- Magacho, G. R. & McCombie, J. S.L. (2017). Verdoorn’s law and productivity dynamics: An empirical investigation into the demand and supply approaches. *Journal of post Keynesian economics*, 40(4): 600-621.

Magrini, S. (2007). *Analysing convergence through the distribution dynamics approach: why and how?* University Ca'Foscari of Venice, Dept. of Economics Research Paper Series No, 13.

Magrini, S. (2009). Why should we analyse convergence using the distribution dynamics approach? Why Should We Analyse Convergence Using the Distribution Dynamics Approach? *Italian Journal of regional Science*, 8(1): 1000-1030.

Mameli, F., Faggian, A., & Mccann, P. (2014). Estimation of local employment growth: Do sectoral aggregation and industry definition matter? *Regional Studies*, 48(11): 1813–1828.

Mankiw, N. G., Romer, D. & Weil, D. (1992). A contribution to the empirics of economic growth. *The Quarterly Journal of Economics*, Cambridge, 107(2): 407-437.

Marconi, N., Reis, C. F. B. & Araújo, E. L. (2016). Manufacturing and economic development: The actuality of Kaldor's first and second laws. *Structural Change and Economic Dynamics*, 37: 75-89.

Marinho, E. L. L., Nogueira, C. A.G. & Rosa, A. L. T. (2002). Evidências empíricas da lei de Kaldor-Verdoorn para a indústria de transformação do Brasil (1985-1997). *Revista Brasileira de Economia*, 56(3): 457-482.

Martin, B. C., McNally, J. J., & Kay, M. J. (2013). Examining the formation of human capital in entrepreneurship: A meta-analysis of entrepreneurship education outcomes. *Journal of business venturing*, 28(2): 211-224.

Massing, N., & Schneider, S. L. (2017). Degrees of competency: the relationship between educational qualifications and adult skills across countries. *Large-scale Assessments in Education*, 5: 1-34.

Mendes, P. S., Hermeto, A. M., & Britto, G. (2019). Reorganização espacial da indústria de transformação brasileira pós-2008: a evolução do emprego formal no território. *Revista Brasileira de Estudos Regionais e Urbanos*, 13(1): 23-44,

Mincer, J. (1958). Investment in human capital and personal income distribution. *Journal of political economy*, 66(4): 281-302.

Monteiro Neto, A., Silva, R. de O., & Severian, D. (2019). Perfil e dinâmica das desigualdades regionais no Brasil em territórios industriais relevantes. Brasília: Ipea. (*Texto para Discussão*), n. 2511.

Morceiro, P. C. (2018) *A indústria brasileira no limiar do século XXI: uma análise da sua evolução estrutural, comercial e tecnológica*, Tese (Doutorado) - Faculdade de Economia, Administração e Contabilidade, Universidade de São Paulo, São Paulo.

Moreira, M. M., & Najberg, S. (1997). Abertura comercial: criando ou exportando Empregos? BNDES *Discussion paper*, No.59 Oct., Rio de Janeiro

Morrissey, K. (2016). A location quotient approach to producing regional production multipliers for the irish economy. *Papers in Regional Science*, 95(3): 491–506.

Motowidlo, S. J., Borman, W. C., & Schmit, M. J. (2014). A theory of individual differences in task and contextual performance. In *Organizational Citizenship Behavior and Contextual Performance* (pp. 71-83). Psychology Press.

- Neves, E. C. d. (2018). *Habilidades, mudanças de firma e prêmio salarial urbano*. Tese (Doutorado) - Universidade de São Paulo. São Paulo.
- Neves, E. C. d., Azzoni, C. R., & Squarize Chagas, A. L., et al. (2019). Habilidades e prêmio salarial urbano. *Technical report*, Núcleo de Economia Regional e Urbana da Universidade de São Paulo (NEREUS).
- Neves, E. C., Azzoni, C. R., & Chagas, A. S. (2021). Habilidades e prêmio salarial urbano. *Pesquisa e Planejamento Econômico*, 51(2).
- Ng, T. W., & Feldman, D. C. (2010). Human capital and objective indicators of career success: The mediating effects of cognitive ability and conscientiousness. *Journal of Occupational and Organizational Psychology*, 83(1): 207-235.
- Nogueira, T. B. (2017). Análise do impacto da sindicalização na produtividade do trabalho na indústria brasileira. (*Dissertação Mestrado*). Insper: São Paulo -BR.
- Oreiro, J. L. & Feijó, C. A. (2010). Desindustrialização: conceituação, causas, efeitos e o caso brasileiro. *Revista de Economia Política*, 30(2): 219-232.
- Parikh, A. (1978). Differences in growth rates and Kaldor's laws. *Economica*, 45(177): 83-91.
- Pauli, R. C. D., Nakabashi, L., & Sampaio, A. V. (2013). Efeitos do comércio internacional e de fatores de oferta na escolaridade dos trabalhadores brasileiros. *Revista de Economia Contemporânea*, 17: 302-323.
- Paz, L. S. (2018). The effect of import competition on Brazil's manufacturing labor market in the 2000s: Are imports from China different? *The International Trade Journal*, 32(1): 76-99.
- Pelinescu, E. (2015). The impact of human capital on economic growth. *Procedia Economics and Finance*, 22: 184-190.
- Popova, Y., & Petrov, I. (2020). Impact of the Human Capital Factors on the Country Competitiveness. In *Reliability and Statistics in Transportation and Communication: Selected Papers from the 19th International Conference on Reliability and Statistics in Transportation and Communication*, RelStat'19, 16-19 October 2019, Riga, Latvia (pp. 662-671). Springer International Publishing.
- Postiglione, P., Andreano, M. S. & Benedetti, R. (2017). Spatial clusters in EU productivity growth. *Growth and Change*, 48(1): 40-60.
- Potter, A. & Watts, H. D. (2014). Revisiting marshall's agglomeration economies: Technological relatedness and the evolution of the sheffield metals cluster. *Regional Studies*, 48(4): 603-623.
- Puga, D. (2010). The magnitude and causes of agglomeration economies. *Journal of regional science*, 50(1): 203-219.
- Quah, D. (1993a) Galton's Fallacy and Tests of the Convergence Hypothesis. *Scandinavian Journal of Economics*, 95: 427-443.
- Quah, D. (1996a) Empirics for Economic Growth and Convergence. *European Economic Review*, 40: 1353-75.
- Quah, D. (1996b) Twin Peaks: Growth and Convergence in Models of Distribution Dynamics. *Economic Journal*, 106: 1045-1055.

- Quah, D. (1996c) Convergence Empirics Across Economies with (Some) Capital Mobility. *Journal of Economic Growth*, 1: 95–124.
- Raguseo, E., Gastaldi, L. & Neirotti, P. (2016). Smart work: supporting employees' flexibility through ICT, HR practices and office layout. *In: Evidence-based HRM: A Global Forum for Empirical Scholarship*, vol. 4. Emerald Group Publishing Limited, 3: 240–256.
- Redding, S. & Venables, A. J. (2004). Economic geography and international inequality. *Journal of international Economics*, 62(1): 53–82.
- Ribeiro, R. S. M., McCombie, J. S. L. & Lima, G. T. (2020). Does real exchange rate undervaluation really promote economic growth? *Structural Change and Economic Dynamics*, 52: 408-417.
- Rios, V., & Gianmoena, L. (2018). Convergence in CO2 emissions: a spatial economic analysis with cross-country interactions. *Energy Economics*, 75: 222-238.
- Rocha, L. A., Silva, N. G. A., Almeida, C. A. S. D., Oliveira, D. M. D., & Fernandes, K. C. (2020). Growth and heterogeneity of human capital: effects of the expansion of higher education on the income increase in Brazilian municipalities. *CEPAL Review*, 131: 87-108.
- Rodrik, D. (2009). Growth after the Crisis. *Globalization and Growth*, 125:126.
- Rodrik, D. (2016). Premature deindustrialization. *Journal of economic growth*, 21(1): 1-33.
- Romer, P. M. (1990). Endogenous technological change. *Journal of political Economy*, 98(5, Part 2): S71–S102.
- Rowthorn, R. E. (1975). What remains of Kaldor's Law? *The Economic Journal*, 85(337): 10-19.
- Rowthorn, R., & Ramaswamy, R. (1999). Growth, trade, and deindustrialization. *IMF Staff papers*, 46(1): 18-41.
- Royuela, V., & García, G. A. (2015). Economic and social convergence in Colombia. *Regional Studies*, 49(2): 219-239.
- Saboia, J. (2013). A continuidade do processo de desconcentração regional da indústria brasileira nos anos 2000. *Nova economia*, 23: 219-278.
- Sala-i-Martin, X. (1996) The Classical Approach to Convergence Analysis. *Economic Journal*, 106: 1019–1036.
- Salvato, M. A., Sant'Anna, P. H., & Da Silva, L. (2008). A. Evolução da balança comercial brasileira no período de câmbio flutuante. *Revista Economia & Tecnologia*, 4(2): 05-18.
- Santos, G. R. dos. (2013). Agroindústria e desenvolvimento: uma análise da distribuição regional e dos efeitos diretos na economia. In: Boueri, R.; Costa, M.A. (Ed.). *Brasil em desenvolvimento 2013: Estado, planejamento e políticas públicas*. Brasília: Ipea, 2, 363-397.
- Schettini, D. & Azzoni, C. R. (2013). Diferenciais regionais de competitividade industrial do Brasil no século 21. *Economia*, 14(1B).
- Schettini, D. & Azzoni, C. R. (2018). Productive efficiency and the future of regional disparities in Brazil. *Nova Economia*, 28: 347–379.
- Schultz, T. W. (1963). *The economic value of education*. Columbia University Press.

- Schwab, K. (2017). *The Fourth Industrial Revolution*. New York: Crown Business.
- Schwab, K., & Davis, N. (2019). *Shaping the Future of the Fourth Industrial Revolution*. New York: Crown Business.
- Serbin, L. A., Stack, D. M., & Kingdon, D. (2013). Academic success across the transition from primary to secondary schooling among lower-income adolescents: Understanding the effects of family resources and gender. *Journal of youth and adolescence*, 42: 1331-1347.
- Sheather S. J. & Jones M. C. (1991) A reliable data-based bandwidth selection method for kernel density estimation, *Journal of the Royal Statistical Society*, 53: 683–690.
- Siddiqui, N., Gorard, S., & See, B. H. (2019). Can programmes like Philosophy for Children help schools to look beyond academic attainment? *Educational review*, 71(2): 146-165.
- Silva, A. L. F. & Diniz, M. B. (2020). Regional concentration patterns of the Brazilian manufacturing industry. *Nova Economia*, 30(2): 407–454.
- Silva, M. V. B. & Neto, R. d. M. S. (2007). Crescimento do emprego industrial no Brasil e geografia econômica: Evidências para o período pós-real. *Revista EconomiA*, 8(2): 269-288.
- Silveira Neto, R. (2005). Concentração industrial regional, especialização geográfica e geografia econômica: evidências para o Brasil no período 1950-2000. *Revista Econômica do Nordeste, Fortaleza*, 36.2: 189-208.
- Silverman, B. W. (1986). *Density estimation for statistics and data analysis* (Vol. 26). CRC press.
- Sobrinho, E. M. G., & Azzoni, C. R. (2015). Aglomerações industriais relevantes do Brasil em 2010. *Revista Brasileira de Estudos Regionais e Urbanos*, 9(1): 1-18.
- Solow, R.M. (1956). A contribution to the theory of economic growth. *The quarterly journal of economics*, 70(1): 65-94.
- Sorenson, O., & Audia, P. G. (2000). The social structure of entrepreneurial activity: Geographic concentration of footwear production in the United States, 1940–1989. *American Journal of Sociology*, 106(2): 424-462.
- Souto-Otero, M., & Białowolski, P. (2021). Graduate employability in Europe: the role of human capital, institutional reputation and network ties in European graduate labour markets. *Journal of Education and Work*, 34(5-6): 611-631.
- Stakhovych, S., & Bijmolt, T. H.A. (2009). Specification of spatial models: A simulation study on weights matrices. *Papers in Regional Science*, 88(2): 389-408.
- Stock, T., Obenaus, M., Kunz, S. & Kohl, H. (2018). Industry 4.0 as enabler for a sustainable development: a qualitative assessment of its ecological and social potential. *Process Safety and Environmental Protection*, 118: 254–267.
- Stoneman, P. (1979). Kaldor's law and British economic growth: 1800–1970. *Applied Economics*, 11(3): 309-319.
- Sulzbach, V. N. (2020). Essays on job polarization in the Brazilian labor market. 2020. 112 f. Tese (Doutorado) – Universidade Federal do Rio Grande do Sul, Faculdade de Ciências Econômicas, Programa de Pós-Graduação em Economia, Porto Alegre.

- Swann, P. (1998). *Clusters in the US computing industry*. Swann, P., M. Prevezer and D. Stout (eds.), 76-105.
- Szirmai, A. & Verspagen, B. (2015). Manufacturing and economic growth in developing countries, 1950–2005. *Structural Change and Economic Dynamics*, 34: 46-59.
- Timmer, M., de Vries, G. J., & De Vries, K. (2015). Patterns of structural change in developing countries. *In* Routledge handbook of industry and developmen. Routledge: 79-97.
- Unger, J. M., Rauch, A., Frese, M., & Rosenbusch, N. (2011). Human capital and entrepreneurial success: A meta-analytical review. *Journal of business venturing*, 26(3): 341-358.
- Wef (2016). *The Future of Jobs: Employment, Skills and Workforce Strategy for the Fourth Industrial Revolution*, World Economic Forum.
- Wells, H. & Thirlwall, A. P. (2003). Testing Kaldor's growth laws across the countries of Africa. *African development review*, 15(2-3): 89-105.
- Xue, Z., Li, N., Mu, H., Zhang, M., & Pang, J. (2021). Convergence analysis of regional marginal abatement cost of carbon dioxide in China based on spatial panel data models. *Environmental Science and Pollution Research*, 28: 38929-38946.
- Zhang, X., & Yu, J. (2018). Spatial weights matrix selection and model averaging for spatial autoregressive models. *Journal of Econometrics*, 203(1): 1-18.

APÊNDICE

APÊNDICE A – EMPREGO NA INDÚSTRIA PRIVADA NO BRASIL

Tabela A.1: Emprego na indústria privada por setor em 2003 e 2019

2003			2019		
CNAE	Descrição	Emprego	CNAE	Descrição	Emprego
14126	Confecção de peças do vestuário, exceto roupas íntimas	404586	10139	Fabricação de produtos de carne	516608
33210	Instalação de máquinas e equipamentos industriais	345643	33210	Instalação de máquinas e equipamentos industriais	511314
32922	Fabricação de equipamentos e acessórios para segurança e proteção pessoal	267155	10121	Abate de suínos, aves e outros pequenos animais	505681
15408	Fabricação de partes para calçados, de qualquer material	263490	14126	Confecção de peças do vestuário, exceto roupas íntimas	467747
32990	Fabricação de produtos diversos	257302	32922	Fabricação de equipamentos e acessórios para segurança e proteção pessoal	346866
10139	Fabricação de produtos de carne	246414	32990	Fabricação de produtos diversos	320993
10121	Abate de suínos, aves e outros pequenos animais	221646	10112	Abate de reses, exceto suínos	287789
33295	Instalação de equipamentos não especificados anteriormente	220422	15408	Fabricação de partes para calçados, de qualquer material	250066
15319	Fabricação de calçados de couro	196576	10716	Fabricação de açúcar em bruto	248904
10716	Fabricação de açúcar em bruto	188251	33295	Instalação de equipamentos não especificados anteriormente	240749
...
24423	Metalurgia dos metais preciosos	1036	20223	Fabricação de intermediários para plastificantes, resinas e fibras	1354
30326	Fabricação de peças e acessórios para veículos ferroviários	1012	30326	Fabricação de peças e acessórios para veículos ferroviários	1323
30504	Fabricação de veículos militares de combate	969	33155	Manutenção e reparação de veículos ferroviários	1309
20339	Fabricação de elastômeros	806	20339	Fabricação de elastômeros	1250
33112	Manutenção e reparação de tanques, reservatórios metálicos e caldeiras	559	18300	Reprodução de materiais gravados em qualquer suporte	1248
33121	Manutenção e reparação de equipamentos eletrônicos e ópticos	545	20118	Fabricação de cloro e álcalis	1209
20941	Fabricação de catalisadores	509	24423	Metalurgia dos metais preciosos	771
19101	Coquerias	255	20941	Fabricação de catalisadores	529
26809	Fabricação de mídias virgens, magnéticas e ópticas	251	19101	Coquerias	489
19225	Fabricação de produtos derivados do petróleo	36	26809	Fabricação de mídias virgens, magnéticas e ópticas	16

Fonte: Brasil (2023d).

Tabela A.2: Emprego na indústria privada por ocupação em 2003 e 2019

2003			2019		
CBO	Descrição	Emprego	CBO	Descrição	Emprego
784205	Alimentador de linha de produção	666543	784205	Alimentador de linha de produção	1385519
411005	Auxiliar de escritório	269026	411005	Auxiliar de escritório	289500
763210	Costureiro na confecção em série	152364	848520	Magarefe	246656
862150	Operador de máquinas ficas em geral	145489	411010	Assistente administrativo	240921
721215	Operador de máquinas-ferramenta convencionais	138912	862150	Operador de máquinas ficas em geral	218381
764005	Trabalhador polivalente da confecção de calçados	128783	414105	Almoxarife	179538
848520	Magarefe	119619	724315	Soldador	178498
763215	Operador de máquina para costura de peças do vestuário	118794	911305	Mecânico de manutenção de máquinas em geral	169841
764115	Preparador de calçados	116544	782510	Motorista de caminhão	168264
911305	Mecânico de manutenção de máquinas em geral	108780	763210	Costureiro na confecção em série	166537
...
213115	Eletrotécnico na fabricação, montagem e instalação de máquinas e equipamentos	1	515325	Sócio educador	1
632340	Trabalhador da exploração de malva (pãina)	1	811610	Operador de carro de apagamento e coque	1
203510	Pesquisador em economia	1	122730	Diretor de crédito (exceto crédito imobiliário)	1
203120	Pesquisador em matemática	1	225130	Médico de família e comunidade	1
632335	Trabalhador da exploração de copaíba	1	213435	Petrógrafo	1
223148	Médico patologista clínico	1	31110	Técnico de laboratório de análises físico-químicas	1
122120	Diretor de produção e operações em empresa pesqueira	1	351735	Técnico de resseguros	1
203415	Pesquisador em ciências da zootecnia	1	233135	Professor de tecnologia e cálculo técnico	1
612610	Produtor de cacau	1	234120	Professor de computação	1
341225	Patrão de pesca na navegação interior	1	122715	Direto de crédito rural	1

Fonte: Brasil (2023d).

APÊNDICE B – Classificação dos segmentos da indústria de transformação

Tabela B.1: Classificação das indústrias em Agroindústria (A) e Não Agroindústria (NA)

CNAE 2.0 (Divisão)	Setor	Tipo de Indústrias
10	Fabricação de produtos alimentícios	A
11	Fabricação de bebidas	A
12	Fabricação de produtos do fumo	A
13	Fabricação de produtos têxteis	A
14	Confecção de artigos do vestuário e acessórios	A
15	Preparação de couros e fabricação de artefatos de couro, artigos para viagem e calçados	A
16	Fabricação de produtos de madeira	A
17	Fabricação de celulose, papel e produtos de papel	A
18	Impressão e reprodução de gravações	NA
19	Fabricação de coque, de produtos derivados do petróleo e de biocombustíveis	A
20	Fabricação de produtos químicos	NA
21	Fabricação de produtos farmoquímicos e farmacêuticos	NA
22	Fabricação de produtos de borracha e de material plástico	NA
23	Fabricação de produtos de minerais não-metálicos	NA
24	Metalurgia	NA
25	Fabricação de produtos de metal, exceto máquinas e equipamentos	NA
26	Fabricação de equipamentos de informática, produtos eletrônicos e ópticos	NA
27	Fabricação de máquinas, aparelhos e materiais elétricos	NA
28	Fabricação de máquinas e equipamentos	NA
29	Fabricação de veículos automotores, reboques e carrocerias	NA
30	Fabricação de outros equipamentos de transporte, exceto veículos automotores	NA
31	Fabricação de móveis	A
32	Fabricação de produtos diversos	NA
33	Manutenção, reparação e instalação de máquinas e equipamentos	NA

Fonte: Favro & Alves (2020). A: Agroindústria; NA: Não Agroindústria.

Tabela B.2: Classificação das indústrias intensivas em capital e trabalho

CNAE 2.0 (Divisão)	Setor	Tipo de Indústrias
10	Fabricação de produtos alimentícios	L
11	Fabricação de bebidas	L
12	Fabricação de produtos do fumo	L
13	Fabricação de produtos têxteis	L
14	Confecção de artigos do vestuário e acessórios	L
15	Preparação de couros e fabricação de artefatos de couro, artigos para viagem e calçados	L
16	Fabricação de produtos de madeira	L
17	Fabricação de celulose, papel e produtos de papel	L
18	Impressão e reprodução de gravações	K
19	Fabricação de coque, de produtos derivados do petróleo e de biocombustíveis	K
20	Fabricação de produtos químicos	K
21	Fabricação de produtos farmoquímicos e farmacêuticos	K
22	Fabricação de produtos de borracha e de material plástico	L
23	Fabricação de produtos de minerais não-metálicos	L
24	Metalurgia	K
25	Fabricação de produtos de metal, exceto máquinas e equipamentos	K
26	Fabricação de equipamentos de informática, produtos eletrônicos e ópticos	K
27	Fabricação de máquinas, aparelhos e materiais elétricos	K
28	Fabricação de máquinas e equipamentos	K
29	Fabricação de veículos automotores, reboques e carrocerias Fabricação de outros equipamentos de transporte, exceto veículos automotores	K
30		K
31	Fabricação de móveis	L
32	Fabricação de produtos diversos	L
33	Manutenção, reparação e instalação de máquinas e equipamentos	L

Fonte: Nogueira (2017), Lisboa et al. (2010), Moreira & Najberg (1997) e Silveira Neto (2005). K: Indústria de capital intensivo; L: Indústria de mão de obra intensiva.

APÊNDICE C – Compatibilização do grau de instrução e o tempo de ensino**Tabela C.1: Compatibilização dos anos de estudo da RAIS**



Descrição	Grau instrução	Anos de estudo
Analfabeto	1	0
Até 5º ano incompleto	2	2
5º ano completo (fundamental)	3	4
6º ano e 9º ano (fundamental)	4	4
Fundamental completo	5	8
Médio incompleto	6	8
Médio completo	7	11
Superior incompleto	8	11
Superior completo	9	14
Mestrado	10	16
Doutorado	11	16
Ignorado	-1	0

Fonte: Bernardelli et al. (2019) e Barros, Castro & Menezes Filho (2023).



APÊNDICE D - ESTATÍSTICAS DESCRITIVAS

Figura D.1: Estatísticas descritivas da taxa de crescimento das habilidades (média geral)



Cognitivas



Sociais




Motoras




Fonte: elaborado pelo autor (2023).

Figura D.2: Estatísticas descritivas da taxa de crescimento das habilidades (mediana)


Cognitivas



Sociais




Motoras




Fonte: elaborado pelo autor (2023).

Figura D.3: Estatísticas descritivas da taxa de crescimento das habilidades (média do último quartil)


Cognitivas



Sociais




Motoras



Fonte: elaborado pelo autor (2023).


Figura D.4: Estatísticas descritivas da taxa de crescimento da escolaridade (média)




Fonte: elaborado pelo autor (2023).

Figura D.5: Estatísticas descritivas das intensidades (média)


Cognitivas



Sociais



Motoras



Fonte: elaborado pelo autor (2023).

APÊNDICE E – CONVERGÊNCIA CONDICIONAL GLOBAL PARA AS HABILIDADES, ESCOLARIDADE E INTENSIDADE

Tabela E.1: Escolha da matriz espacial para as regressões de convergência condicional global para as habilidades

Habilidades	Modelo	Média		Mediana		Média do último quartil	
		k-nearest	AIC	k-nearest	AIC	k-nearest	AIC
Cognitivas	SDM	26	-31912.05	22	-25684.93	23	-36089.5
	SAR	26	-31855.56	20	-25642.38	6	-36093.9
	SEM	26	-31897.27	22	-25668.62	8	-36094.3
Sociais	SDM	4	-33216.53	4	-24445.15	13	-30379.17
	SAR	30	-33209.52	25	-24413.19	6	-30373.17
	SEM	26	-33212.26	1	-24426.34	1	-30373.15
Motoras	SDM	26	-27509.77	22	-19731.42	28	-47840.1
	SAR	13	-27454.12	30	-19696.91	4	-47807.46
	SEM	26	-27485.17	26	-19719.29	29	-47814.82

Fonte: elaborado pelo autor (2023).

Tabela E.2: Regressão espacial para as notas médias de habilidade da indústria (2003-2019)

Var.	Cognitivas				Sociais				Motoras			
	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM
β	-0.384*** (0.029)	-0.395*** (0.029)	-0.382*** (0.029)	-0.391*** (0.030)	-0.461*** (0.038)	-0.462*** (0.037)	-0.461*** (0.038)	-0.462*** (0.038)	-0.435*** (0.021)	-0.446*** (0.021)	-0.433*** (0.021)	-0.441*** (0.021)
θ		0.239*** (0.042)				0.061*** (0.023)				0.283*** (0.046)		
ρ		0.299*** (0.053)	0.217*** (0.056)			0.018 (0.018)	0.042 (0.051)			0.024*** (0.048)	0.125*** (0.034)	
λ				0.317*** (0.052)				0.080* (0.042)				0.268*** (0.046)
Φ	0.037	0.039	0.037	0.038	0.048	0.048	0.048	0.048	0.044	0.045	0.044	-0.441
MV	8.083	7.783	8.143	7.890	6.331	6.318	6.330	6.319	6.860	6.630	6.890	(0.021)
<i>RGI FE</i>	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim
<i>Time FE</i>	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim
Obs.	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872
R2	0.229	0.210	0.189	0.199	0.256	0.241	0.237	0.238	0.255	0.241	0.227	0.231
LogLik	15910.73	15960.22	15930.78	15951.64	16607.26	16612.27	16607.76	16609.13	13718.67	13758.89	13730.06	13745.59
AIC	-31789.46	-31912.05	-31855.56	-31897.27	-33182.52	-33216.54	-33209.53	-33212.26	-27405.34	-27509.77	-27454.12	-27485.18
BIC	-31677.92	-31884.16	-31834.65	-31876.36	-33070.98	-33188.65	-33188.61	-33191.35	-27293.81	-27481.89	-27433.21	-27464.26
LMI	25.973***				0.4108				10.324***			
RLMI	10.611***				4.7312**				10.148***			
LMe	48.511***				2.9539*				25.272***			
RLMe	33.148***				7.2742***				25.095***			
Teste de Wald		Prob>Chi2	Resultado		Prob>Chi2	Resultado		Prob>Chi2	Resultado		Prob>Chi2	Resultado
$\theta = 0$ and $\rho \neq 0$		0.0000	SAR \neq SDM		0.0087	SAR \neq SDM		0.0000	SAR \neq SDM		0.0002	SAR \neq SDM
$\theta = -\beta\rho$		0.0064	SEM \neq SDM		0.0465	SEM \neq SDM						SEM \neq SDM

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto. Φ : velocidade implícita. MV: Meia-vida

Tabela E.3: Efeito direto, indireto e total da regressão espacial para as notas médias das habilidades

Efeitos	Cognitivas		Sociais		Motoras	
	SDM		SDM		SDM	
	Coef.	p-value	Coef.	p-value	Coef.	p-value
Direto						
β	-0.392 (0.029)	***	-0.460 (0.039)	***	-0.443 (0.022)	***
Indireto						
β	0.166 (0.059)	***	0.051 (0.010)	**	0.224 (0.057)	***
Total						
β	-0.226 (0.071)	***	-0.408 (0.044)	***	-0.218 (0.061)	***

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela E.4: Regressão espacial para a mediana das habilidades da indústria (2003-2019)

Var.	Cognitivas				Sociais				Motoras			
	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM
β	-0.412*** (0.045)	-0.418*** (0.045)	-0.411*** (0.046)	-0.417*** (0.046)	-0.571*** (0.068)	-0.576*** (0.067)	-0.571*** (0.068)	-0.575*** (0.068)	-0.446*** (0.025)	-0.454*** (0.024)	-0.445*** (0.025)	-0.451*** (0.025)
θ		0.063*** (0.016)				0.124*** (0.027)				0.233*** (0.051)		
ρ		0.051*** (0.013)	0.147*** (0.038)			0.052*** (0.018)	0.047*** (0.051)			0.225*** (0.038)	0.194*** (0.040)	
λ				0.238*** (0.041)				0.035** (0.016)				0.257*** (0.036)
Φ	0.041	0.042	0.041	0.042	0.065	0.066	0.065	0.066	0.045	0.047	0.045	0.046
MV	7.360	7.236	7.392	7.242	4.620	4.556	4.621	4.579	6.616	6.460	6.642	6.530
<i>RGI FE</i>	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim
<i>Time FE</i>	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim
Obs.	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872
R2	0.229	0.220	0.216	0.219	0.308	0.304	0.301	0.302	0.245	0.236	0.229	0.233
LogLik	12813.58	12830.83	12824.19	12837.31	12208.78	12226.58	12209.60	12216.17	9838.14	9896.71	9851.46	9862.64
AIC	-25595.16	-25653.66	-25642.38	-25668.63	-24385.56	-24445.15	-24413.19	-24426.34	-19644.27	-19731.42	-19696.91	-19719.28
BIC	-25483.62	-25625.78	-25621.47	-25647.71	-24274.03	-24417.27	-24392.28	-24405.43	-19532.74	-19703.54	-19676.00	-19698.37
LMI	13.184***				0.0306				6.719***			
RLMI	10.005***				18.62***				9.7797***			
LMe	27.864***				6.0871**				17.574***			
RLMe	24.685***				24.677***				20.635***			
Teste de Wald		Prob>Chi2	Resultado		Prob>Chi2	Resultado		Prob>Chi2	Resultado		Prob>Chi2	Resultado
$\theta = 0$ and $\rho \neq 0$		0.0001	SAR \neq SDM		0.0000	SAR \neq SDM		0.0000	SAR \neq SDM		0.0070	SAR \neq SDM
$\theta = -\beta\rho$		0.0055	SEM \neq SDM		0.0001	SEM \neq SDM						SEM \neq SDM

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto. Φ : velocidade implícita. MV: Meia-vida

Tabela E.5: Efeito direto, indireto e total da regressão espacial para a mediana das habilidades

Efeitos	Cognitivas		Sociais		Motoras	
	SDM		SDM		SDM	
	Coef.	p-value	Coef.	p-value	Coef.	p-value
Direto						
β	-0.415 (0.046)	***	-0.572 (0.069)	***	-0.452 (0.025)	***
Indireto						
β	0.042 (0.015)	***	0.096 (0.024)	***	0.164 (0.060)	***
Total						
β	-0.372 (0.050)	***	-0.476 (0.071)	***	-0.287 (0.067)	***

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela E.6: Regressão espacial para a média do último quartil das habilidades da indústria (2003-2019)

Var.	Cognitivas				Sociais				Motoras			
	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM
β	-0.476*** (0.028)	-0.477*** (0.028)	-0.476*** (0.028)	-0.477*** (0.028)	-0.475*** (0.023)	-0.477*** (0.023)	-0.475*** (0.023)	-0.475*** (0.023)	-0.417*** (0.031)	-0.424*** (0.033)	-0.416*** (0.031)	-0.419*** (0.032)
θ		0.104* (0.056)				0.111** (0.047)				0.220*** (0.067)		
ρ		0.116*** (0.038)	0.060*** (0.021)			0.029 (0.035)	-0.034 (0.023)			0.075* (0.041)	0.018 (0.016)	
λ				0.074*** (0.026)				0.016 (0.013)				0.126*** (0.046)
Φ	0.050	0.050	0.050	0.050	0.050	0.050	0.050	0.050	0.041	0.042	0.041	0.042
MV	6.055	6.037	6.060	6.046	6.077	6.029	6.076	6.075	7.261	7.103	7.265	7.202
<i>RGI FE</i>	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim
<i>Time FE</i>	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim
Obs.	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872
R2	0.414	0.233	0.229	0.230	0.304	0.250	0.245	0.233	0.232	0.231	0.224	0.225
LogLik	18044.95	18050.63	18049.97	18050.15	15187.99	15193.59	15189.58	15189.57	23906.04	23924.04	23906.73	23910.41
AIC	-36057.90	-36093.26	-36093.93	-36094.30	-30343.98	-30379.17	-30373.17	-30373.15	-47780.07	-47804.08	-47807.46	-47814.82
BIC	-35946.36	-36065.37	-36073.02	-36073.38	-30232.45	-30351.29	-30352.25	-30352.23	-47668.54	-47812.19	-47786.55	-47793.90
LMI	6.7098***				2.02				0.32			
RLMI	0.05				11.632***				17.348***			
LMe	8.6482***				0.00				1.42			
RLMe	1.98				9.6161***				18.444***			
Teste de Wald		Prob>Chi2	Resultado		Prob>Chi2	Resultado		Prob>Chi2	Resultado		Prob>Chi2	Resultado
$\theta = 0$ and $\rho \neq 0$		0.0633	SAR \neq SDM		0.0187	SAR \neq SDM		0.0010	SAR \neq SDM		0.0026	SEM \neq SDM
$\theta = -\beta\rho$		0.3499	SEM = SDM		0.0318	SEM \neq SDM						

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto. Φ : velocidade implícita. MV: Meia-vida.

Tabela E.7: Efeito direto, indireto e total da regressão espacial para a média do último quartil de habilidades

Efeitos	Sociais		Motoras	
	SAR		SDM	
	Coef.	p-value	Coef.	p-value
	Direto			
β	-0.476 (0.028)	***	-0.421 (0.033)	***
	Indireto			
β	0.096 (0.044)	**	0.198 (0.067)	***
	Total			
β	-0.380 (0.047)	***	-0.223 (0.062)	***

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela E.8: Escolha da matriz espacial para as regressões de convergência condicional global para a escolaridade

Variável	Modelo	Média	
		k-nearest	AIC
Escolaridade	SDM	15	-26373.27
	SAR	11	-26177.99
	SEM	11	-26317.33

Fonte: elaborado pelo autor (2023).

Tabela E.9: Escolha da matriz espacial para as regressões de convergência condicional global para a intensidade de habilidades

Intensidade	Modelo	Média	
		k-nearest	AIC
Cognitivas	SDM	15	-21642.54
	SAR	12	-21529.77
	SEM	30	-21605.45
Sociais	SDM	16	-19921.18
	SAR	12	-19819.43
	SEM	15	-19882.55
Motoras	SDM	10	-25817.66
	SAR	11	-25654.31
	SEM	11	-25780.49

Fonte: elaborado pelo autor (2023).

Tabela E.10: Regressão espacial para a intensidade das habilidades da indústria (2003-2019)

Var.	Cognitivas				Sociais				Motoras			
	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM
β	-0.356*** (0.038)	-0.378*** (0.040)	-0.354*** (0.038)	-0.370*** (0.040)	-0.391*** (0.038)	-0.412*** (0.038)	-0.390*** (0.038)	-0.404*** (0.039)	-0.323*** (0.025)	-0.357*** (0.027)	-0.317*** (0.025)	-0.346*** (0.027)
θ		0.244*** (0.041)				0.258*** (0.043)				0.225*** (0.028)		
ρ		0.295*** (0.034)	0.207*** (0.034)			0.264*** (0.033)	0.171*** (0.032)			0.338*** (0.39)	0.278*** (0.042)	
λ				0.413*** (0.042)				0.290*** (0.033)				0.376*** (0.039)
Φ	0.034	0.037	0.034	0.036	0.038	0.041	0.038	0.040	0.030	0.034	0.029	0.033
MV	8.893	8.230	8.971	8.477	7.891	7.380	7.930	7.558	10.032	8.873	10.263	9.204
<i>RGI FE</i>	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim
<i>Time FE</i>	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim
Obs.	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872
R2	0.220	0.1762	0.092	0.114	0.242	0.197	0.110	0.1301	0.209	0.178	0.105	0.131
LogLik	10730.96	10825.27	10767.89	10805.73	9888.55	9964.594	9912.72	9944.279	12752.36	12912.83	12830.16	12893.25
AIC	-21429.92	-21642.54	-21529.78	-21605.46	-19745.10	-19921.19	-19819.43	-19882.56	-25472.71	-25817.67	-25654.32	-25780.49
BIC	-21318.38	-21614.66	-21508.86	-21584.55	-19633.56	-19893.30	-19798.52	-19861.64	-25361.18	-25789.78	-25633.40	-25759.58
LMI	43.667***				22.464***				89.865***			
RLMI	42.493***				40.763***				80.869***			
LMe	102.19***				67.807***				198.48***			
RLMe	101.01***				86.106***				189.48***			
Teste de Wald	Prob>Chi2		Resultado		Prob>Chi2		Resultado		Prob>Chi2		Resultado	
$\theta = 0$ and $\rho \neq 0$	0.0000		SAR \neq SDM		0.0000		SAR \neq SDM		0.0000		SAR \neq SDM	
$\theta = -\beta\rho$	0.0003		SEM \neq SDM		0.0001		SEM \neq SDM		0.0000		SEM \neq SDM	

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela E.11: Efeito direto, indireto e total da regressão espacial para a intensidade de habilidades

Efeitos	Cognitivas		Sociais		Motoras	
	SDM		SDM		SDM	
	Coef.	p-value	Coef.	p-value	Coef.	p-value
	Direto					
β	-0.374 (0.041)	***	-0.407 (0.039)	***	-0.351 (0.028)	***
	Indireto					
β	0.181 (0.049)	***	0.197 (0.050)	***	0.150 (0.033)	***
	Total					
β	-0.192 (0.055)	***	-0.210 (0.058)	***	-0.201 (0.038)	***

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

APÊNDICE F – HETEROGENEIDADE INDUSTRIAL

Tabela F.1: Escolha da matriz espacial para as regressões de convergência condicional global para as habilidades da agroindústria e não agroindústria

Habilidades	Modelo	Agroindústria		Não Agroindústria	
		k-nearest	AIC	k-nearest	AIC
Cognitivas	SDM	26	-27708.8	26	-30687.9
	SAR	28	-27653.5	29	-30677.1
	SEM	26	-27694	1	-30678.8
Sociais	SDM	21	-22824.2	27	-23418
	SAR	13	-22773.9	29	-23389.2
	SEM	22	-22804.6	6	-23390.4
Motoras	SDM	19	-28592.9	27	-23418
	SAR	29	-28555.3	29	-23389.2
	SEM	22	-28565.7	6	-23390.4

Fonte: elaborado pelo autor (2023).

Tabela F.2: Regressão espacial para as habilidades da agroindústria (2003-2019)

Var.	Cognitivas				Sociais				Motoras			
	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM
β	-0.404*** (0.030)	-0.416*** (0.031)	-0.402*** (0.030)	-0.412*** (0.031)	-0.451*** (0.021)	-0.461*** (0.021)	-0.449*** (0.021)	-0.457*** (0.021)	-0.488*** (0.027)	-0.493*** (0.027)	-0.488*** (0.027)	-0.490*** (0.027)
θ		0.245*** (0.040)				0.251*** (0.039)				0.247*** (0.049)		
ρ		0.292*** (0.050)	0.215*** (0.052)			0.214*** (0.040)	0.122*** (0.030)			0.066 (0.040)	0.038 (0.040)	
λ				0.309*** (0.049)				0.245*** (0.041)				0.125*** (0.035)
Φ	0.040	0.041	0.040	0.041	0.046	0.048	0.046	0.047	0.051	0.052	0.051	0.052
MV	7.548	7.280	7.605	7.378	6.532	6.331	6.558	6.412	5.852	5.764	5.851	5.804
<i>RGI FE</i>	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim
<i>Time FE</i>	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim
Obs.	7856	7856	7856	7856	7856	7856	7856	7856	7856	7856	7856	7856
R2	0.2342	0.2226	0.2110	0.2177	0.2579	0.2485	0.2441	0.2462	0.2689	0.2661	0.2613	0.2618
LogLik	13810.99	13858.40	13829.75	13849.99	10379.33	11416.10	11389.96	11405.2900	14280.26	14300.47	14280.67	14285.87
AIC	-27589	-27589.97	-27653.50	-27693.98	-22726.66	-22824.20	-22773.93	-22804.59	-28528.53	-28592.95	-28555.34	-28565.73
BIC	-27478.47	-27478.47	-27632.59	-27673.07	-22615.16	-22796.32	-22753.02	-22783.68	-28417.02	-28565.07	-28534.43	-28544.83
LMI	47.466***				24.527***				0.011			
RLMI	32.705***				21.211***				1.159			
LMe	24.956***				11.191***				0.129			
RLMe	10.195***				7.875***				1.278*			
Constraint	Prob>Chi2				Prob>Chi2				Prob>Chi2			
$\theta = 0$ and $\rho \neq 0$	0.0000	SAR \neq SDM			0.0000	SAR \neq SDM			0.0000	SAR \neq SDM		
$\theta = -\beta\rho$	0.0024	SEM \neq SDM			0.0001	SEM \neq SDM			0.0000	SEM \neq SDM		

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela F.3: Efeito direto, indireto e total da regressão espacial para as habilidades da agroindústria

Efeitos	Cognitivas		Sociais		Motoras	
	SDM		SDM		SDM	
	Coef.	p-value	Coef.	p-value	Coef.	p-value
Direto						
β	-0.413 (0.318)	***	-0.458 (0.022)	***	-0.491 (0.028)	***
Indireto						
β	0.168 (0.053)	***	0.188 (0.046)	***	0.225 (0.051)	***
Total						
β	-0.244 (0.065)	***	-0.270 (0.049)	***	-0.265 (0.049)	***

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela F.4: Regressão espacial para as habilidades da não agroindústria (2003-2019)

Var.	Cognitivas				Sociais				Motoras			
	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM
β	-0.483*** (0.035)	-0.484*** (0.034)	-0.483*** (0.034)	-0.484*** (0.034)	-0.480*** (0.030)	-0.485*** (0.030)	-0.480*** (0.030)	-0.481*** (0.030)	-0.486*** (0.037)	-0.487*** (0.036)	-0.486*** (0.037)	-0.487*** (0.037)
θ		0.178*** (0.069)				0.249*** (0.061)				0.023* (0.013)		
ρ		-0.592 (0.041)	-0.119 (0.045)			-0.145 (0.044)	-0.094 (0.046)			0.024* (0.014)	0.155 (0.014)	
λ				0.026*** (0.012)				0.048*** (0.017)				0.024* (0.014)
Φ	0.051	0.051	0.051	0.051	0.050	0.051	0.050	0.050	0.051	0.051	0.051	0.051
MV	5.931	5.907	5.936	5.919	5.986	5.894	5.989	5.963	5.872	5.861	5.875	5.864
<i>RGI FE</i>	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim
<i>Time FE</i>	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim
Obs.	7600	7600	7600	7600	7600	7600	7600	7600	7600	7600	7600	7600
R2	0.2626	0.2460	0.2324	0.2263	0.2602	0.2510	0.2360	0.2318	0.2550	0.2336	0.2321	0.2328
LogLik	15338.27	15347.93	15341.53	15342.42	11695.45	11713.02	11697.58	11698.1900	13936.27	13940.39	13938.04	13939.70
AIC	-30644.55	-30687.86	-30677.06	-30678.85	-23358.90	-23418.03	-23389.17	-23390.38	-27840.54	-27872.77	-27870.08	-27873.40
BIC	-30533.57	-30660.12	-30656.26	-30658.04	-23247.93	-23390.29	-23368.36	-23369.58	-27729.56	-27845.03	-27849.27	-27852.59
LMI	6.492***				4.492**				0.001			
RLMI	12.961***				13.346***				2.548			
LMe	0.962				0.443*				3.730			
RLMe	7.432***				9.298***				3.277*			
Constraint	Prob>Chi2				Prob>Chi2				Prob>Chi2			
$\theta = 0$ and $\rho \neq 0$	0.0109	SAR \neq SDM			0.0001	SAR \neq SDM			0.0843	SAR \neq SDM		
$\theta = -\beta\rho$	0.0022	SEM \neq SDM			0.0000	SEM \neq SDM			0.4218	SEM = SDM		

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela F.5: Efeito direto, indireto e total da regressão espacial para as habilidades da não agroindústria

Efeitos	Cognitivas		Sociais	
	SDM		SDM	
	Coef.	p-value	Coef.	p-value
Direto				
β	-0.483 (0.035)	***	-0.484 (0.031)	***
Indireto				
β	0.192 (0.061)	**	0.249 (0.057)	***
Total				
β	-0.290 (0.075)	***	-0.234 (0.060)	***

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela F.6: Escolha da matriz espacial para as regressões de convergência condicional global para as habilidades das indústrias intensivas em capital e intensivas em trabalho

Habilidades	Modelo	Intensiva em capital		Intensiva em trabalho	
		k-nearest	AIC	k-nearest	AIC
Cognitivas	SDM	15	-24846.25	26	-31027.09
	SAR	5	-24833.30	27	-30992.63
	SEM	6	-24836.92	26	-31035.15
Sociais	SDM	30	-19484.08	26	-26181.98
	SAR	24	-19472.77	27	-26113.55
	SEM	26	-19474.09	26	-26151.62
Motoras	SDM	26	-20607.04	27	-32556.34
	SAR	4	-20599.40	7	-32544.77
	SEM	4	-20594.80	30	-32545.54

Fonte: elaborado pelo autor (2023).

Tabela F.7: Regressão espacial para as habilidades da indústria intensiva em capital (2003-2019)

Var.	Cognitivas				Sociais				Motoras			
	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM
β	-0.484*** (0.025)	-0.488*** (0.025)	-0.484*** (0.025)	-0.485*** (0.025)	-0.498*** (0.023)	-0.500*** (0.023)	-0.498*** (0.023)	-0.499*** (0.023)	-0.483*** (0.019)	-0.486*** (0.019)	-0.483*** (0.019)	-0.482*** (0.019)
θ		0.156*** (0.047)				0.183*** (0.064)				0.185*** (0.065)		
ρ		0.056* (0.031)	0.026 (0.020)			0.036 (0.043)	-0.030 (0.041)			-0.025 (0.041)	-0.043 (0.018)	
λ				0.051*** (0.022)				0.060 (0.039)				-0.026 (0.018)
Φ	0.051	0.051	0.051	0.051	0.053	0.053	0.053	0.053	0.051	0.051	0.051	0.051
MV	5.918	5.851	5.919	5.900	5.678	5.639	5.677	5.665	5.926	5.881	5.933	5.940
<i>RGI FE</i>	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim
<i>Time FE</i>	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim
Obs.	6928	6928	6928	6928	6928	6928	6928	6928	6928	6928	6928	6928
R2	0.2665	0.2542	0.2452	0.2462	0.2753	0.2668	0.2621	0.2614	0.2438	0.2383	0.2337	0.2326
LogLik	12418.68	12427.13	12419.65	12421.46	9739.11	9746.04	9739.387	9740.0490	10299.37	10307.52	10302.70	10300.40
AIC	-24805.36	-24846.26	-24833.31	-24836.92	-19466.21	-19484.08	-19472.77	-19474.10	-20566.74	-20607.04	-20599.40	-20594.81
BIC	-24695.87	-24818.88	-24812.78	-24816.39	-19336.72	-19456.71	-19452.24	-19453.57	-20457.24	-20579.67	-20578.87	-20574.28
LMI	1.489				3.115*				0.538			
RLMI	3.188*				4.630**				3.003*			
LMe	0.279				0.971				2.277			
RLMe	1.979				2.486				4.742**			
Constraint		Prob>Chi2				Prob>Chi2				Prob>Chi2		
$\theta = 0$ and $\rho \neq 0$	0.0010		SAR \neq SDM		0.0045		SAR \neq SDM		0.0046		SAR \neq SDM	
$\theta = -\beta\rho$	0.0029		SEM \neq SDM		0.0092		SEM = SDM		0.0029		SEM = SDM	

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela F.8: Efeito direto, indireto e total da regressão espacial para as habilidades da indústria intensiva em capital

Efeitos	Cognitivas		Sociais		Motoras	
	SDM		SDM		SDM	
	Coef.	p-value	Coef.	p-value	Coef.	p-value
	Direto					
β	-0.486 (0.025)	***	-0.499 (0.023)	***	-0.485 (0.020)	***
	Indireto					
β	0.132 (0.044)	***	0.167 (0.063)	***	0.188 (0.062)	***
	Total					
β	-0.353 (0.050)	***	-0.332 (0.065)	***	-0.296 (0.058)	***

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela F.9: Regressão espacial para as habilidades da indústria intensiva em trabalho (2003-2019)

Var.	Cognitivas				Sociais				Motoras			
	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM
β	-0.387*** (0.026)	-0.396*** (0.026)	-0.385*** (0.026)	-0.393*** (0.027)	-0.433*** (0.021)	-0.446*** (0.021)	-0.432*** (0.020)	-0.440*** (0.021)	-0.484*** (0.029)	-0.485*** (0.029)	-0.483*** (0.029)	-0.485*** (0.029)
θ		0.212*** (0.040)				0.293*** (0.041)				0.192*** (0.063)		
ρ		0.298*** (0.055)	0.226*** (0.057)			0.236*** (0.050)	0.145*** (0.054)			0.056 (0.044)	-0.037 (0.027)	
λ				0.309*** (0.055)				0.268*** (0.047)				0.086** (0.042)
Φ	0.038	0.039	0.037	0.038	0.044	0.045	0.044	0.045	0.051	0.051	0.051	0.051
MV	7.990	7.763	8.058	7.842	6.889	6.627	6.909	6.736	5.910	5.889	5.918	5.896
<i>RGI FE</i>	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim
<i>Time FE</i>	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim
Obs.	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872
R2	0.2331	0.2142	0.1985	0.2077	0.2565	0.2442	0.2360	0.2397	0.2763	0.2689	0.2649	0.2642
LogLik	14577.48	15521.58	15499.32	15516.55	13051.87	13094.99	13059.78	13078.8100	16273.79	16282.17	16275.39	16275.77
AIC	-30922.96	-31035.15	-30992.63	-31027.10	-26071.74	-26181.98	-26113.55	-26151.62	-32515.58	-32556.34	-32544.77	-32545.55
BIC	-30811.42	-31007.27	-30971.72	-31006.18	-25960.20	-26154.10	-26092.64	-26130.71	-32404.05	-32528.46	-32523.86	-32524.63
LMI	39.955***				15.948***				0.002			
RLMI	24.106***				20.870***				1.040			
LMe	22.491***				5.033**				0.203			
RLMe	6.642***				9.955***				1.242*			
Constraint	Prob>Chi2				Prob>Chi2				Prob>Chi2			
$\theta = 0$ and $\rho \neq 0$	0.0000	SAR \neq SDM			0.0000	SAR \neq SDM			0.0024	SAR \neq SDM		
$\theta = -\beta\rho$	0.0230	SEM \neq SDM			0.0000	SEM \neq SDM			0.0090	SEM \neq SDM		

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela F.10: Efeito direto, indireto e total da regressão espacial para as habilidades da indústria intensiva em trabalho

Efeitos	Cognitivas		Sociais		Motoras	
	SDM		SDM		SDM	
	Coef.	p-value	Coef.	p-value	Coef.	p-value
Direto						
β	-0.393 (0.027)	***	-0.443 (0.021)	***	-0.484 (0.030)	***
Indireto						
β	0.127 (0.054)	***	0.239 (0.011)	***	0.169 (0.023)	**
Total						
β	-0.266 (0.064)	***	-0.203 (0.054)	***	-0.314 (0.067)	***

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela F.11: Escolha da matriz espacial para as regressões de convergência condicional global para a escolaridade da agroindústria, não agroindústrias, indústrias intensivas em capital e intensivas em trabalho

Modelo	Agroindústria		Não Agroindústria		Intensivo em capital		Intensivo em trabalho	
	k-nearest	AIC	k-nearest	AIC	k-nearest	AIC	k-nearest	AIC
SDM	14	-22246.2	29	-24756.4	30	-18900.6	10	-25255.9
SAR	13	-22070.3	10	-24626.4	10	-18833.7	30	-25077.5
SEM	14	-22191.5	29	-24669	28	-18856.2	30	-25220

Fonte: elaborado pelo autor (2023).

Tabela F.12: Resultado das regressões para a escolaridade da agroindústria

Var.	OLS (1)	SDM (2)	SAR (3)	SEM (4)
β	-0.407*** (0.040)	-0.441*** (0.042)	-0.402*** (0.040)	-0.430*** (0.042)
θ		0.291*** (0.037)		
ρ		0.316*** (0.044)	0.217*** (0.046)	
λ				0.356*** (0.039)
Φ (velocidade implícita)	0.040	0.045	0.040	0.043
MV (meia-vida)	7.494	6.724	7.602	6.959
<i>RGI FE</i>	sim	sim	sim	sim
<i>Time FE</i>	sim	sim	sim	sim
Observations	7856	7856	7856	7856
R2	0.249	0.208	0.110	0.136
LogLik	10998.80	11127.12	11038.15	11098.77
AIC	-21968.61	-22246.24	-22070.29	-22191.54
BIC	-21854.10	-22218.36	-22049.39	-22170.64
LM test, no spatial lag	176.920***			
Robust LM test, no spatial lag	186.550***			
LM test, no spatial error	67.882***			
Robust LM test, no spatial error	77.514***			
Teste de Wald		Prob>Chi2		Resultado
$\theta = 0$ e $\rho \neq 0$		0.0000		SAR \neq SDM
$\theta = -\lambda \beta$		0.0000		SEM \neq SDM

Fonte: elaborado pelo autor (2023). Nota: nível de significância ***<0.01; **<0.05 e *<0.1. Erro Padrão Robusto.

Tabela F.13: Efeito direto, indireto e total da regressão espacial para escolaridade da agroindústria

Efeitos	SDM	
	Coef.	p-value
	Direto	
β	-0.436 (0.043)	***
	Indireto	
β	0.215 (0.044)	***
	Total	
β	-0.221 (0.051)	***

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela F.14: Resultado das regressões para a escolaridade da não agroindústria

Var.	OLS (1)	SDM (2)	SAR (3)	SEM (4)
β	-0.313*** (0.020)	-0.321*** (0.021)	-0.313*** (0.020)	-0.317*** (0.021)
θ		0.087*** (0.018)		
ρ		0.067*** (0.015)	0.036** (0.015)	
λ				0.070*** (0.015)
Φ (velocidade implícita)	0.029	0.030	0.029	0.029
MV (meia-vida)	10.414	10.111	10.418	10.272
<i>RGI FE</i>	sim	sim	sim	sim
<i>Time FE</i>	sim	sim	sim	sim
Observations	7600	7600	7600	7600
R2	0.198	0.147	0.121	0.124
LogLik	12312.35	12338.08	12315.58	12323.74
AIC	-24592.69	-24668.15	-24625.17	-24641.49
BIC	-24481.72	-24640.41	-24604.36	-24620.68
LM test, no spatial lag	11.247***			
Robust LM test, no spatial lag	73.559***			
LM test, no spatial error	0.026			
Robust LM test, no spatial error	62.338***			
Teste de Wald		Prob>Chi2		Resultado
$\theta = 0$ e $\rho \neq 0$		0.0000		SAR \neq SDM
$\theta = -\lambda \beta$		0.0001		SEM \neq SDM

Fonte: elaborado pelo autor (2023). Nota: nível de significância ***<0.01; **<0.05 e *<0.1. Erro Padrão Robusto.

Tabela F.15: Efeito direto, indireto e total da regressão espacial para a escolaridade da não agroindústria

Efeitos	SDM	
	Coef.	p-value
	Direto	
β	-0.319 (0.022)	***
	Indireto	
β	0.067 (0.017)	***
	Total	
β	-0.251 (0.023)	***

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela F.16: Resultado das regressões para a escolaridade da indústria intensiva em capital

Var.	OLS (1)	SDM (2)	SAR (3)	SEM (4)
β	-0.435*** (0.032)	-0.449*** (0.033)	-0.435*** (0.032)	-0.443*** (0.033)
θ		0.293*** (0.059)		
ρ		0.110* (0.066)	0.018 (0.054)	
λ				0.206*** (0.062)
Φ (velocidade implícita)	0.044	0.046	0.044	0.045
MV (meia-vida)	6.847	6.567	6.847	6.689
<i>RGI FE</i>	sim	sim	sim	sim
<i>Time FE</i>	sim	sim	sim	sim
Observations	6928	6928	6928	6928
R2	0.253	0.244	0.157	0.160
LogLik	9418.78	9454.31	9418.89	9431.09
AIC	-18805.57	-18900.62	-18831.78	-18856.18
BIC	-18696.08	-18873.25	-18811.25	-18835.65
LM test, no spatial lag	20.233***			
Robust LM test, no spatial lag	24.508***			
LM test, no spatial error	7.121***			
Robust LM test, no spatial error	11.396***			
Teste de Wald		Prob>Chi2		Resultado
$\theta = 0$ e $\rho \neq 0$		0.0000		SAR \neq SDM
$\theta = -\lambda \beta$		0.0000		SEM \neq SDM

Fonte: elaborado pelo autor (2023). Nota: nível de significância ***<0.01; **<0.05 e *<0.1. Erro Padrão Robusto.

Tabela F.17: Efeito direto, indireto e total da regressão espacial para a escolaridade da indústria intensiva em capital

Efeitos	SDM	
	Coef.	p-value
	Direto	
β	-0.446 (0.034)	***
	Indireto	
β	0.269 (0.060)	***
	Total	
β	-0.177 (0.061)	***

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela F.18: Resultado das regressões para a escolaridade da indústria intensiva em trabalho

Var.	OLS (1)	SDM (2)	SAR (3)	SEM (4)
β	-0.357*** (0.038)	-0.394*** (0.042)	-0.350*** (0.038)	-0.381*** (0.041)
θ		0.255*** (0.038)		
ρ		0.320*** (0.045)	0.363*** (0.062)	
λ				0.503*** (0.050)
Φ (velocidade implícita)	0.034	0.039	0.033	0.037
MV (meia-vida)	8.855	7.811	9.069	8.159
<i>RGI FE</i>	sim	sim	sim	sim
<i>Time FE</i>	sim	sim	sim	sim
Observations	7872	7872	7872	7872
R2	0.228	0.183	0.084	0.122
LogLik	12473.32	12631.97	12541.74	12612.98
AIC	-24914.65	-25255.95	-25077.48	-25219.95
BIC	-24803.11	-25228.06	-25056.56	-25199.04
LM test, no spatial lag	20.233***			
Robust LM test, no spatial lag	24.508***			
LM test, no spatial error	7.121***			
Robust LM test, no spatial error	11.396***			
Teste de Wald		Prob>Chi2		Resultado
$\theta = 0$ e $\rho \neq 0$		0.0000		SAR \neq SDM
$\theta = -\lambda \beta$		0.0000		SEM \neq SDM

Fonte: elaborado pelo autor (2023). Nota: nível de significância ***<0.01; **<0.05 e *<0.1. Erro Padrão Robusto.

Tabela F.19: Efeito direto, indireto e total da regressão espacial para a escolaridade da indústria intensiva em trabalho

Efeitos	SDM	
	Coef.	p-value
	Direto	
β	-0.388 (0.043)	***
	Indireto	
β	0.181 (0.043)	***
	Total	
β	-0.207 (0.047)	***

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela F.20: Escolha da matriz espacial para as regressões de convergência condicional global para as intensidades de habilidades da agroindústria e não agroindústria

Intensidade	Modelo	Agroindústria		Não Agroindústria	
		k-nearest	AIC	k-nearest	AIC
Cognitivas	SDM	17	-17713.8	29	-20339.6
	SAR	12	-17633.5	8	-20271.6
	SEM	20	-17686.1	8	-20291.8
Sociais	SDM	8	-21396	29	-17340.1
	SAR	13	-21361.8	2	-17320.3
	SEM	13	-21270.1	7	-17324.4
Motoras	SDM	8	-21396	21	-23132.8
	SAR	13	-21361.8	4	-22961.6
	SEM	13	-21270.1	30	-23014.7

Fonte: elaborado pelo autor (2023).

Tabela F.21: Regressão espacial para as intensidades de habilidades da agroindústria (2003-2019)

Var.	Cognitivas				Sociais				Motoras			
	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM
β	-0.422*** (0.034)	-0.439*** (0.034)	-0.419*** (0.034)	-0.431*** (0.034)	-0.432*** (0.032)	-0.445*** (0.027)	-0.413*** (0.027)	-0.435*** (0.028)	-0.418*** (0.027)	-0.444*** (0.028)	-0.414*** (0.027)	-0.435*** (0.029)
θ		0.254*** (0.040)				0.236*** (0.026)				0.270*** (0.033)		
ρ		0.244*** (0.037)	0.152*** (0.034)			0.253*** (0.252)	0.228*** (0.042)			0.301*** (0.042)	0.208*** (0.041)	
λ				0.295*** (0.037)				0.333*** (0.038)				0.361*** (0.042)
Φ	0.042	0.045	0.042	0.043	0.044	0.045	0.041	0.044	0.042	0.045	0.041	0.044
MV	7.144	6.761	7.203	6.933	6.917	6.654	7.342	6.862	7.222	6.670	7.329	6.856
<i>RGI FE</i>	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim
<i>Time FE</i>	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim
Obs.	7856	7856	7856	7856	7856	7856	7856	7856	7856	7856	7856	7856
R2	0.2524	0.2031	0.1237	0.1431	0.2479	0.1895	0.1135	0.1409	0.2479	0.1998	0.1161	0.1409
LogLik	8800.214	8860.92	8819.75	8846.07	10594.36	10702.01	10638.03	10683.89	10594.36	10684.97	10632.83	10671.67
AIC	-17568.43	-17713.83	-17633.50	-17686.14	-21156.73	-21396.02	-21270.06	-21361.78	-21156.73	-21361.95	-21259.67	-21337.33
BIC	-17456.92	-17685.96	-17612.59	-17665.23	-21045.22	-21368.14	-21249.16	-21304.87	-21045.22	-21334.07	-21238.76	-21316.42
LMI	89.251***				65.069***				151.870***			
RLMI	79.811***				74.609***				139.860***			
LMe	38.560***				22.913***				65.822***			
RLMe	29.120***				32.454***				53.815***			
Constraint	Prob>Chi2				Prob>Chi2				Prob>Chi2			
$\theta = 0$ and $\rho \neq 0$	0.0000	SAR \neq SDM			0.0000	SAR \neq SDM			0.0000	SAR \neq SDM		
$\theta = -\beta\rho$	0.0001	SEM \neq SDM			0.0001	SEM \neq SDM			0.0001	SEM \neq SDM		

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela F.22: Efeito direto, indireto e total da regressão espacial para as intensidades de habilidades da agroindústria

Efeitos	Cognitivas		Sociais		Motoras	
	SDM		SDM		SDM	
	Coef.	p-value	Coef.	p-value	Coef.	p-value
Direto						
β	-0.436 (0.035)	***	-0.439 (0.028)	***	-0.440 (0.029)	***
Indireto						
β	0.189 (0.047)	***	0.158 (0.030)	***	0.189 (0.040)	***
Total						
β	-0.246 (0.054)	***	-0.281 (0.409)	***	-0.251 (0.045)	***

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela F.23: Regressão espacial para as intensidades de habilidades da não agroindústria (2003-2019)

Var.	Cognitivas				Sociais				Motoras			
	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM
β	-0.355*** (0.024)	-0.366*** (0.025)	-0.354*** (0.023)	-0.359*** (0.024)	-0.401*** (0.026)	-0.404*** (0.026)	-0.401*** (0.026)	-0.402*** (0.026)	-0.366*** (0.021)	-0.399*** (0.022)	-0.366*** (0.021)	-0.384*** (0.022)
θ		0.269*** (0.042)				0.198*** (0.065)				0.315*** (0.037)		
ρ		0.064*** (0.048)	0.053*** (0.022)			0.004 (0.050)	0.020 (0.012)			0.089** (0.039)	0.030 (0.020)	
λ				0.117*** (0.025)				0.060** (0.023)				0.291*** (0.041)
Φ	0.034	0.035	0.034	0.034	0.039	0.040	0.039	0.040	0.035	0.039	0.035	0.037
MV	8.937	8.575	8.941	8.803	7.642	7.549	7.641	7.616	8.580	7.673	8.584	8.062
<i>RGI FE</i>	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim
<i>Time FE</i>	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim
Obs.	7600	7600	7600	7600	7600	7600	7600	7600	7600	7600	7600	7600
R2	0.2075	0.2060	0.1120	0.1177	0.2293	0.1969	0.1308	0.1331	0.2149	0.2306	0.1424	0.1458
LogLik	10136.05	10173.81	10138.82	10148.90	8661.46	8674.06	8663.143	8665.1780	11482.01	11570.42	11483.78	11510.36
AIC	-20240.11	-20339.62	-20271.64	-20291.81	-17290.91	-17340.12	-17320.29	-17324.36	-22932.01	-23132.83	-22961.55	-23014.72
BIC	-20129.13	-20311.88	-20250.83	-20271.00	-17179.94	-17312.38	-17299.48	-17303.55	-22821.04	-23105.09	-22940.75	-22993.91
LMI	11.771***				5.208***				19.193***			
RLMI	44.728***				17.094***				118.330***			
LMe	0.342				0.352				0.009			
RLMe	33.299***				12.238***				99.145***			
Constraint	Prob>Chi2				Prob>Chi2				Prob>Chi2			
$\theta = 0$ and $\rho \neq 0$	0.0000	SAR \neq SDM			0.0001	SAR \neq SDM			0.0000	SAR \neq SDM		
$\theta = -\beta\rho$	0.0000	SEM \neq SDM			0.0000	SEM \neq SDM			0.0000	SEM \neq SDM		

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela F.24: Efeito direto, indireto e total da regressão espacial para as intensidades de habilidades da não agroindústria

Efeitos	Cognitivas		Sociais		Motoras	
	SDM		SDM		SDM	
	Coef.	p-value	Coef.	p-value	Coef.	p-value
Direto						
β	-0.365 (0.026)	***	-0.403 (0.027)	***	-0.397 (0.023)	***
Indireto						
β	0.259 (0.049)	***	0.193 (0.061)	***	0.303 (0.039)	***
Total						
β	-0.105 (0.047)	***	-0.210 (0.063)	***	-0.094 (0.035)	***

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela F.25: Escolha da matriz espacial para as regressões de convergência condicional global para as intensidades de habilidades das indústrias intensivas em capital e intensivas em trabalho

Habilidades	Modelo	Intensiva em capital		Intensiva em trabalho	
		k-nearest	AIC	k-nearest	AIC
Cognitivas	SDM	30	-14161.9	30	-20742.9
	SAR	11	-14115.0	30	-20657.9
	SEM	28	-14126.7	30	-20728.6
Sociais	SDM	30	-12612.9	30	-18839.0
	SAR	25	-12593.6	30	-18749.7
	SEM	11	-12594.7	30	-18818.4
Motoras	SDM	29	-17392.3	10	-24539.6
	SAR	3	-17328.3	13	-24394.3
	SEM	20	-17345.4	13	-24505.2

Fonte: elaborado pelo autor (2023).

Tabela F.26: Regressão espacial para as intensidades de habilidades da indústria intensiva em capital (2003-2019)

Var.	Cognitivas				Sociais				Motoras			
	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM
β	-0.463*** (0.030)	-0.473*** (0.031)	-0.463*** (0.030)	-0.467*** (0.031)	-0.477*** (0.024)	-0.481*** (0.024)	-0.477*** (0.024)	-0.478*** (0.024)	-0.416*** (0.028)	-0.430*** (0.029)	-0.416*** (0.028)	-0.422*** (0.029)
θ		0.278*** (0.060)				0.208*** (0.064)				0.290*** (0.060)		
ρ		0.088 (0.059)	0.279 (0.033)			0.024 (0.054)	0.012 (0.028)			0.083*** (0.051)	0.022*** (0.017)	
λ				0.154*** (0.055)				0.045 (0.048)				0.161*** (0.051)
Φ	0.048	0.049	0.048	0.048	0.050	0.051	0.050	0.050	0.041	0.043	0.041	0.042
MV	6.296	6.112	6.296	6.211	6.040	5.957	6.040	6.024	7.274	6.965	7.278	7.144
<i>RGI FE</i>	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim
<i>Time FE</i>	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim
Obs.	6928	6928	6928	6928	6928	6928	6928	6928	6928	6928	6928	6928
R2	0.2650	0.2464	0.1724	0.1761	0.2727	0.2421	0.1893	0.1908	0.2321	0.2325	0.1677	0.1702
LogLik	7059.977	7084.49	7060.52	7066.33	6298.88	6310.47	6298.99	6299.4140	8665.93	8700.13	8667.14	8675.70
AIC	-14087.95	-14160.98	-14115.05	-14126.65	-12565.77	-12612.95	-12591.98	-12592.83	-17299.86	-17392.25	-17328.29	-17345.41
BIC	-13978.46	-14133.61	-14094.52	-14106.12	-12456.28	-12585.57	-12571.45	-12572.30	-17190.36	-17364.88	-173073.76	-17324.88
LMI	10.146***				8.245***				26.090***			
RLMI	12.775***				4.432**				40.680***			
LMe	3.407*				4.798**				8.089***			
RLMe	6.036**				0.984				22.679***			
Constraint		Prob>Chi2				Prob>Chi2				Prob>Chi2		
$\theta = 0$ and $\rho \neq 0$	0.0000	SAR \neq SDM			0.0012	SAR \neq SDM			0.0000	SAR \neq SDM		
$\theta = -\beta\rho$	0.0000	SEM \neq SDM			0.0014	SEM \neq SDM			0.0000	SEM \neq SDM		

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela F.27: Efeito direto, indireto e total da regressão espacial para as habilidades da indústria intensiva em capital

Efeitos	Cognitivas		Sociais		Motoras	
	SDM		SDM		SDM	
	Coef.	p-value	Coef.	p-value	Coef.	p-value
	Direto					
β	-0.471 (0.031)	***	-0.480 (0.025)	***	-0.428 (0.030)	***
	Indireto					
β	0.253 (0.061)	***	0.196 (0.061)	***	0.273 (0.059)	***
	Total					
β	-0.218 (0.063)	***	-0.283 (0.061)	***	-0.155 (0.058)	***

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela F.28: Regressão espacial para as intensidades de habilidades da indústria intensiva em trabalho (2003-2019)

Var.	Cognitivas				Sociais				Motoras			
	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM
β	-0.395*** (0.036)	-0.409*** (0.037)	-0.390*** (0.036)	-0.405*** (0.037)	-0.417*** (0.036)	-0.432*** (0.037)	-0.414*** (0.036)	-0.428*** (0.037)	-0.362*** (0.025)	-0.391*** (0.026)	-0.355*** (0.024)	-0.381*** (0.027)
θ		0.260*** (0.048)				0.286*** (0.051)				0.235*** (0.029)		
ρ		0.383*** (0.043)	0.284*** (0.046)			0.352*** (0.042)	0.243*** (0.045)			0.328*** (0.039)	0.281*** (0.044)	
λ				0.404*** (0.041)				0.380*** (0.040)				0.380*** (0.041)
Φ	0.039	0.040	0.038	0.040	0.042	0.044	0.041	0.043	0.035	0.038	0.034	0.037
MV	7.793	7.439	7.925	7.537	7.247	6.907	7.331	7.011	8.711	7.896	8.936	8.155
<i>RGI FE</i>	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim
<i>Time FE</i>	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim	sim
Obs.	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872
R2	0.2387	0.1736	0.0882	0.1208	0.2550	0.2085	0.1133	0.1447	0.2271	0.1780	0.1025	0.1314
LogLik	10295.31	10375.00	10331.96	10367.30	9352.49	9423.52	9377.843	9412.2190	12128.90	12273.79	12200.16	12255.61
AIC	-20558.62	-20742.00	-20657.93	-20728.59	-18672.98	-18839.03	-18749.69	-18818.44	-24225.79	-24539.58	-24394.33	-24505.22
BIC	-20447.08	-20714.11	-20637.01	-20707.68	-18561.44	-18811.15	-18728.77	-18797.53	-24114.25	-24511.70	-24373.41	-24484.31
LMI	102.980***				71.700***				192.690***			
RLMI	102.030***				88.125***				180.980***			
LMe	42.201***				23.286***				84.530***			
RLMe	41.255***				39.712***				72.819***			
Constraint	Prob>Chi2				Prob>Chi2				Prob>Chi2			
$\theta = 0$ and $\rho \neq 0$	0.0000	SAR \neq SDM			0.0000	SAR \neq SDM			0.0000	SAR \neq SDM		
$\theta = -\beta\rho$	0.0221	SEM \neq SDM			0.0049	SEM \neq SDM			0.0001	SEM \neq SDM		

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela F.29: Efeito direto, indireto e total da regressão espacial para as intensidades de habilidades da indústria intensiva em trabalho

Efeitos	Cognitivas		Sociais		Motoras	
	SDM		SDM		SDM	
	Coef.	p-value	Coef.	p-value	Coef.	p-value
Direto						
β	-0.406 (0.038)	***	-0.424 (0.038)	***	-0.386 (0.027)	***
Indireto						
β	0.161 (0.070)	***	0.200 (0.070)	***	0.152 (0.036)	**
Total						
β	-0.244 (0.077)	***	-0.228 (0.075)	***	-0.234 (0.043)	***

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

APÊNDICE G – HETEROGENEIDADE ESPACIAL

Tabela G.1: Escolha da matriz espacial para as regressões de convergência condicional das habilidades para as classes de tamanho

Habilidades	Modelo	Média	
		k-nearest	AIC
Cognitivas	SDM	23	-31906.71
	SAR	26	-31852.93
	SEM	26	-31895.59
Sociais	SDM	4	-33214.89
	SAR	24	-33212.04
	SEM	26	-33214.93
Motoras	SDM	26	-27503.29
	SAR	13	-27456.23
	SEM	26	-27485.4

Fonte: elaborado pelo autor (2023).

Tabela G.2: Regressão espacial para as habilidades da indústria por clusters de tamanho ($k = 5$)

Var.	Cognitivas				Sociais				Motoras			
	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM
β	-0.380*** (0.031)	-0.390*** (0.031)	-0.379*** (0.031)	-0.387*** (0.032)	-0.468*** (0.040)	-0.468*** (0.039)	-0.468*** (0.039)	-0.468*** (0.039)	-0.439*** (0.023)	-0.448*** (0.023)	-0.439*** (0.023)	-0.445*** (0.023)
βC_1	0.588** (0.252)	0.657*** (0.239)	0.579** (0.241)	0.657** (0.244)	0.774*** (0.124)	0.664*** (0.187)	0.779*** (0.124)	0.799*** (0.130)	1.100*** (0.237)	1.138*** (0.315)	1.101*** (0.229)	1.125*** (0.237)
βC_2	0.434** (0.172)	0.264 (0.220)	0.431** (0.171)	0.306 (0.186)	0.645*** (0.188)	0.646*** (0.215)	0.646*** (0.189)	0.634*** (0.191)	1.256*** (0.212)	0.874*** (0.221)	1.272*** (0.210)	1.044*** (0.217)
βC_3	-0.367 (0.316)	-0.454 (0.290)	-0.329 (0.304)	-0.372 (0.294)	0.172 (0.174)	0.157 (0.169)	0.174 (0.173)	0.178 (0.173)	-0.115 (0.357)	-0.217 (0.318)	-0.077 (0.350)	-0.143 (0.326)
βC_4	-0.033 (0.291)	-0.057 (0.267)	-0.020 (0.284)	-0.057 (0.274)	0.337* (0.198)	0.325 (0.197)	0.337* (0.198)	0.337* (0.199)	0.268 (0.290)	0.207 (0.256)	0.283 (0.289)	0.265 (0.267)
θ		0.230*** (0.058)				(0.025) -0.524				0.285 (0.061)		
θC_1		-0.033 (3.282)				(0.971) -0.241				-0.502 (4.847)		
θC_2		1.833 (1.826)				(0.587) -0.129				2.440 (2.136)		
θC_3		-1.190 (0.969)				(0.416) 0.524				-0.240 (1.311)		
θC_4		0.695 (0.744)				(0.254) (0.025)				-0.871 (0.881)		
ρ		0.276*** (0.053)	0.215*** (0.055)			0.017 (0.018)	0.034 (0.044)			0.236*** (0.048)	0.126*** (0.034)	
λ				0.317*** (0.052)				0.080* (0.042)				0.265*** (0.047)
<i>RGI FE</i>	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim
<i>Time FE</i>	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim
Obs.	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872
R2	0.230	0.214	0.190	0.200	0.257	0.243	0.239	0.240	0.256	0.2427	0.229	0.233
LogLik	15913.8	15965.36	15933.47	15954.80	16612.61	16619.45	16613.02	16614.47	13723.6	13763.65	13735.12	13749.7
AIC	-31787.6	-31906.7	-31852.93	-31895.59	-33185.21	33214.9	-33212.04	-33214.94	-27407.19	-27503.3	-27456.23	-27485.4
BIC	-31648.18	-31823.1	-31804.14	-31846.80	-33045.79	-33131.24	-33163.25	-33166.14	-27267.77	-27419.65	-27407.44	-27436.6
LMI	25.846***				2.7096*				24.273***			
RLMI	10.44***				6.3608**				22.404***			
LMe	48.824***				0.4104				10.412***			
RLMe	33.418***				4.0644**				8.5428***			
Teste de Wald	Prob>Chi2		Resultado		Prob>Chi2		Resultado		Prob>Chi2		Resultado	
$\theta = 0$ and $\rho \neq 0$	0.0000		SAR \neq SDM		0.0200		SAR \neq SDM		0.0000		SAR \neq SDM	
$\theta = -\beta\rho$	0.0148		SEM \neq SDM		0.0718		SEM = SDM		0.0026		SEM \neq SDM	

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela G.3: Efeito direto, indireto e total da regressão espacial para os clusters de tamanho ($k = 5$)

Efeitos	Cognitivas		Motoras	
	SDM		SDM	
	Coef.	p-value	Coef.	p-value
Direto				
βC_1	0.647 (0.241)	***	1.121 (0.311)	***
βC_2	0.302 (0.214)	ns	0.912 (0.217)	***
βC_3	-0.475 (0.297)	ns	-0.222 (0.323)	ns
βC_4	-0.048 (0.260)	ns	0.200 (0.249)	ns
βC_5	-0.387 (0.032)	***	-0.445 (0.024)	***
Indireto				
βC_1	0.299 (4.777)	ns	-0.205 (6.537)	ns
βC_2	2.514 (2.386)	ns	3.334 (2.660)	ns
βC_3	-1.766 (1.388)	ns	-0.292 (1.725)	ns
βC_4	0.910 (1.008)	ns	-1.081 (1.129)	ns
βC_5	0.171 (0.079)	***	0.235 (0.078)	***
Total				
βC_1	0.946 (4.842)	ns	0.915 (6.597)	ns
βC_2	2.816 (2.396)	ns	4.246 (2.698)	ns
βC_3	-2.241 (1.491)	ns	-0.515 (1.818)	ns
βC_4	0.862 (1.055)	ns	-0.880 (1.174)	ns
βC_5	-0.216 (0.095)	**	-0.210 (0.086)	***

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela G.4: Escolha da matriz espacial para as regressões de convergência condicional da escolaridade para as classes de tamanho

Variável	Modelo	Média	
		k-nearest	AIC
Escolaridade	SDM	15	-26378.4
	SAR	11	-26207.04
	SEM	11	-26334.9

Fonte: elaborado pelo autor (2023).

Tabela G.5: Resultado das regressões de escolaridade por classe de tamanho

Var.	OLS (1)	SDM (2)	SAR (3)	SEM (4)
β	-0.324*** (0.039)	-0.362*** (0.043)	-0.320*** (0.039)	-0.347*** (0.042)
βC_1	-0.160*** (0.029)	-0.086*** (0.023)	-0.161*** (0.029)	-0.114*** (0.030)
βC_2	-0.156*** (0.037)	-0.125** (0.049)	-0.155*** (0.035)	-0.151*** (0.040)
βC_3	-0.153*** (0.026)	-0.119*** (0.026)	-0.156*** (0.025)	-0.134*** (0.024)
βC_4	-0.037 (0.049)	-0.021 (0.043)	-0.041 (0.048)	-0.030 (0.047)
θ		0.263*** (0.042)		
θC_1		-0.217 (0.290)		
θC_2		0.004 (0.244)		
θC_3		-0.007 (0.164)		
θC_4		0.093 (0.110)		
ρ		0.360*** (0.046)	0.262*** (0.047)	
λ				0.367*** (0.042)
RGI FE	sim	sim	sim	sim
Time FE	sim	sim	sim	sim
Observations	7872	7872	7872	7872
R2	0.214	0.190	0.206	0.117
LogLik	13042.88	13201.21	13110.52	13174.43
AIC	-26045.76	-26378.42	-26207.04	-26334.86
BIC	-25906.34	-26294.77	-26158.24	-26286.07
LM test, no spatial lag	79.967***			
Robust LM test, no spatial lag	76.845***			
LM test, no spatial error	180.83***			
Robust LM test, no spatial error	177.71***			
Teste de Wald	Prob>Chi2	Resultado		
$\theta = 0$ and $\rho \neq 0$	0.0000	SAR \neq SDM		
$\theta = -\lambda \beta$	0.0014	SEM \neq SDM		

Fonte: elaborado pelo autor (2023). Nota: nível de significância ***<0.01; **<0.05 e *<0.1. Erro Padrão Robusto.

**Tabela G.6: Efeito direto, indireto e total da regressão espacial
para a escolaridade por classe de tamanho
($k = 5$)**

Efeitos	SDM	
	Coef.	p-value
	Direto	
βC_1	-0.140 (0.034)	***
βC_2	-0.152 (0.038)	***
βC_3	-0.129 (0.025)	***
βC_4	-0.029 (0.048)	ns
βC_5	-0.341 (0.043)	***
	Indireto	
βC_1	-0.055 (0.155)	***
βC_2	0.112 (0.132)	ns
βC_3	-0.029 (0.083)	ns
βC_4	0.002 (0.044)	ns
βC_5	0.096 (0.024)	ns
	Total	
βC_1	-0.195 (0.164)	ns
βC_2	-0.041 (0.125)	ns
βC_3	-0.158 (0.090)	*
βC_4	-0.027 (0.064)	ns
βC_5	-0.245 (0.036)	***

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela G.7: Escolha da matriz espacial para as regressões de convergência condicional para as intensidades de habilidades para as classes de tamanho

Intensidade	Modelo	Média	
		k-nearest	AIC
Cognitivas	SDM	15	-21642.3
	SAR	12	-21538.9
	SEM	15	-21608.02
Sociais	SDM	16	-19916.32
	SAR	12	-19821.7
	SEM	15	-19882.53
Motoras	SDM	10	-25826.42
	SAR	11	-25681.75
	SEM	11	-25797.08

Fonte: elaborado pelo autor (2023).

Tabela G.8: Regressão espacial das intensidades de habilidades por classe de tamanho ($k=5$)

Var.	Cognitivas				Sociais				Motoras			
	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM	OLS	SDM	SAR	SEM
β	-0.357*** (0.038)	-0.380*** (0.040)	-0.355*** (0.038)	-0.371*** (0.040)	-0.391*** (0.038)	-0.412*** (0.039)	-0.390*** (0.038)	-0.404*** (0.039)	-0.328*** (0.025)	-0.360*** (0.027)	-0.322*** (0.024)	-0.349*** (0.027)
βC_1	-0.121** (0.049)	-0.036 (0.044)	-0.122** (0.048)	-0.067 (0.048)	-0.102*** (0.031)	-0.010 (0.044)	-0.104*** (0.031)	-0.049 (0.039)	-0.307*** (0.032)	-0.216*** (0.044)	-0.307*** (0.029)	-0.236*** (0.035)
βC_2	-0.136*** (0.039)	-0.092* (0.054)	-0.134*** (0.038)	-0.117*** (0.042)	-0.094* (0.049)	-0.069 (0.065)	-0.092* (0.048)	-0.084 (0.053)	-0.217*** (0.055)	-0.185*** (0.061)	-0.217*** (0.052)	-0.209*** (0.056)
βC_3	-0.144*** (0.032)	-0.113*** (0.038)	-0.146*** (0.0311)	-0.131*** (0.032)	-0.137*** (0.035)	-0.109* (0.044)	-0.139*** (0.034)	-0.126*** (0.035)	-0.174*** (0.029)	-0.131*** (0.030)	-0.177*** (0.028)	-0.150*** (0.028)
βC_4	-0.011 (0.065)	0.000 (0.061)	-0.016 (0.065)	-0.009 (0.064)	-0.004 (0.066)	0.125 (0.062)	-0.008 (0.066)	-0.001 (0.066)	-0.025 (0.047)	0.002 (0.044)	-0.030 (0.046)	-0.015 (0.045)
θ		0.236*** (0.042)				0.251*** (0.043)				0.214*** (0.028)		
θC_1		-0.718* (0.429)				-0.939 (0.553)				-0.615 (0.345)		
θC_2		-0.260 (0.340)				-0.129 (0.337)				-0.170 (0.295)		
θC_3		0.037 (0.208)				0.073 (0.252)				-0.065 (0.165)		
θC_4		0.129 (0.146)				0.103 (0.178)				-0.039 (0.091)		
ρ		0.292*** (0.034)	0.208*** (0.034)			0.261*** (0.033)	0.171*** (0.033)			0.335*** (0.039)	0.279*** (0.042)	
λ				0.320*** (0.034)				0.288*** (0.033)				0.372*** (0.040)
<i>RGI FE</i>	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim
<i>Time FE</i>	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim
Obs.	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872	7872
R2	0.222	0.174	0.090	0.112	0.243	0.196	0.108	0.129	0.212	0.171	0.102	0.130
LogLik	10739.31	10833.16	10776.44	10811.01	9893.63	9970.16	9917.872	9948.267	12769.19	12925.21	12847.88	12905.54
AIC	-21438.62	-21642.32	-21538.88	-21608.02	-19747.28	-19916.32	-19821.74	-19882.53	-25498.32	-25826.43	-25681.76	-25797.09
BIC	-24299.2	-21558.66	-21490.08	-21559.23	-19607.86	-19832.67	-19772.95	-19833.74	-25358.9	-25742.77	-25632.96	-25748.29
LMI	44.167***				22.707***				91.061***			
RLMI	37.095***				38.341***				64.489***			
LMe	98.989***				66.776***				187.52***			
RLMe	91.916***				82.41***				160.95***			
Teste de Wald		Prob>Chi2	Resultado		Prob>Chi2	Resultado		Prob>Chi2	Resultado		Prob>Chi2	Resultado
$\theta = 0$ and $\rho \neq 0$		0.0000	SAR \neq SDM		0.0000	SAR \neq SDM		0.0000	SAR \neq SDM		0.0000	SAR \neq SDM
$\theta = -\beta\rho$		0.0011	SEM \neq SDM		0.0018	SEM \neq SDM		0.0004	SEM \neq SDM		0.0004	SEM \neq SDM

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.

Tabela G.9: Efeito direto, indireto e total da regressão espacial para a intensidade de habilidade por clusters de tamanho ($k = 5$)

Efeitos	Cognitivas		Sociais		Motoras	
	SDM		SDM		SDM	
	Coef.	p-value	Coef.	p-value	Coef.	p-value
Direto						
βC_1	-0.052 (0.044)	ns	-0.027 (0.043)	ns	-0.242 (0.046)	***
βC_2	-0.093 (0.051)	*	-0.065 (0.062)	ns	-0.175 (0.058)	***
βC_3	-0.113 (0.039)	***	-0.109 (0.046)	**	-0.134 (0.031)	***
βC_4	0.002 (0.061)	ns	0.013 (0.061)	ns	0.003 (0.043)	ns
βC_5	-0.376 (0.041)	***	-0.408 (0.040)	***	-0.355 (0.002)	***
Indireto						
βC_1	-1.001 (0.632)	ns	-1.234 (0.775)	ns	-1.017 (0.537)	*
βC_2	-0.400 (0.461)	ns	-0.198 (0.438)	ns	0.147 (0.403)	ns
βC_3	0.0019 (0.298)	ns	0.072 (0.352)	ns	-0.134 (0.247)	ns
βC_4	0.183 (0.205)	ns	0.146 (0.239)	ns	0.055 (0.137)	ns
βC_5	0.177 (0.051)	***	0.194 (0.051)	***	0.139 (0.035)	***
Total						
βC_1	-1.053 (0.643)	ns	-1.261 (0.780)	ns	-1.259 (0.557)	**
βC_2	-0.493 (0.466)	ns	-0.264 (0.442)	ns	-0.028 (0.411)	ns
βC_3	-0.094 (0.314)	ns	-0.036 (0.375)	ns	-0.269 (0.259)	ns
βC_4	0.186 (0.211)	ns	0.160 (0.241)	ns	0.059 (0.142)	ns
βC_5	-0.198 (0.060)	***	-0.214 (0.061)	***	-0.2163 (0.066)	***

Fonte: elaborado pelo autor (2023). Notas: Nível de significância ***<0,01; **<0,05 e *<0,1. Erro Padrão Robusto.