Publicação Preliminar

FORMA URBANA E MOBILIDADE SUSTENTÁVEL: EVIDÊNCIAS DE CIDADES BRASILEIRAS

Autores(as): Rafael H M Pereira
João Pedro Parga
Marcus Saraiva
João Pedro Bazzo
Diego Tomasiello
Luiz Pedro Silva
Vanessa Nadalin
Rogério Barbosa

Produto editorial: Texto para Discussão
Cidade: Brasília
Editora: Instituto de Pesquisa Econômica Aplicada (Ipea)
Ano: 2022
Edição 1ª

O Ipea informa que este texto não foi objeto de padronização, revisão textual ou diagramação pelo Editorial e será substituído pela sua versão final uma vez que o processo de editoração seja concluído.

FORMA URBANA E MOBILIDADE SUSTENTÁVEL: EVIDÊNCIAS DE CIDADES BRASILEIRAS

Rafael H M Pereira [1]
João Pedro Parga [2]
Marcus Saraiva [2]
João Pedro Bazzo [2]
Diego Tomasiello [2]
Luiz Pedro Silva [2]
Vanessa Nadalin [3]
Rogério Barbosa [4]

RESUMO:
A organização espacial das cidades tem importantes implicações para a sua sustentabilidade ambiental. Diversos estudos têm analisado como características de forma urbana podem ter diferentes impactos ambientais ao influenciar padrões de mobilidade mais ou menos sustentáveis. No entanto, a maioria desses estudos fazem análises empíricas sem um fundamento teórico sobre os canais de causalidade entre forma urbana e padrões de mobilidade. Além disso, a maioria desses estudos analisa cidades em países desenvolvidos, e existem poucas evidências sobre a relação entre forma urbana e mobilidade sustentável no sul global e Brasil. Neste estudo, nós analisamos como a organização espacial das cidades brasileiras impacta o consumo de energia na sua mobilidade urbana. Primeiro, nós apresentamos uma análise descritiva de como as cidades no Brasil têm se desenvolvido espacialmente entre 1990 e 2015. Em seguida, nós usamos análises de regressão para captar em que medida o consumo de energia per capita no transporte individual motorizado das 182 maiores aglomerações urbanas do país é impactado por diferentes características de forma urbana (densidade populacional, mix de uso do solo, compacidade e contiguidade, além da densidade de interseções, conectividade e sinuosidade do sistema viário). As análises de regressão são construídas com base em um Grafo Acíclico Dirigido (DAG) que nós propomos para mapear os canais causais entre forma urbana e energia no transporte a partir de extensa revisão da literatura. Nós constatamos que houve um aumento geral da densidade populacional nas cidades brasileiras entre 1990 e 2015. No entanto, as cidades médias ficaram mais espraiadas e fragmentadas, enquanto cidades grandes ficaram ligeiramente mais compactas e contíguas. Os resultados das regressões apontam que maiores níveis de mix de uso do solo e densidade populacional e compacidade levam a menor uso de energia na mobilidade. No entanto, o efeito da compacidade depende do tamanho da cidade, de maneira que maior compacidade leva a maior consumo energético em grandes cidades, possivelmente refletindo deseconomias de aglomeração. Esses resultados têm implicações mais amplas, mostrando a necessidade de uma visão integrada de políticas locais de uso do solo e transporte para promover cidades menos dependentes do automóvel e padrões de mobilidade mais sustentáveis.

Palavras-chave: forma urbana, mobilidade sustentável, energia no transporte, Brasil

[1] Técnico de planejamento e pesquisa na Diretoria de Estudos e Políticas Regionais, Urbanas e Ambientais (Dirur) do Ipea. E-mail: <rafael.pereira@ipea.gov.br>.
[2] Assistente de pesquisa na Dirur/Ipea.
[3] Técnica de planejamento e pesquisa na Diretoria de Estudos e Políticas Regionais, Urbanas e Ambientais (Dirur) do Ipea.
[4] Professor no Instituto de Estudos Sociais e Políticos (IESP-UERJ)

ABSTRACT:

The spatial organization of cities has important implications for sustainable urban development. Several studies have analyzed how urban form characteristics can have different environmental impacts by influencing more or less sustainable mobility patterns. However, most of these studies present empirical analysis without considering a theoretical understanding regarding the causal paths between urban form and mobility patterns. Moreover, this literature focuses mostly on cities in the Global North, and there is much less evidence about the relationship between urban form and sustainable mobility in the Global South and particularly in Brazil. In this study, we examine the extent to which the urban form of Brazilian cities impacts their urban mobility energy consumption. First, we present a descriptive analysis of how urban areas in Brazil have developed spatially between 1990 and 2015. Next, we use regression models to analyze the extent to which the amount of energy per capita used in private motorized transport in the 182 largest urban areas in Brazil are affected by different characteristics of urban form (population density, land use mix, compacity, contiguity, as well as the intersection density, closeness centrality and circutity of road networks). The regression models are built based upon a Directed Acyclic Graph (DAG) that we propose to map the causal paths between urban form and transport energy use based on an extensive literature review. We found that there was a general increase in population density in all cities between 1990 and 2015. However, medium-size cities became more sprawled and fragmented while large cities became slightly more compact and contiguous. Our regression results show that higher levels of land use mix, population density and compacity lead to lower transport energy use. Moreover, the effect of compacity varies by population size in a way that higher compacity levels lead to higher energy consumption in large cities, possibly reflecting diseconomies of agglomeration. These findings have broader implications that show the need for more integrated local land use and transport policies in shaping less car-dependent cities and more sustainable mobility patterns.

Keywords: urban form, sustainable mobility, transport energy, Brazil

JEL code: R11, R40, R42, R49, R52, R58, N76

1. INTRODUÇÃO

A organização espacial das cidades tem profundo impacto sobre a promoção de áreas urbanas mais ou menos sustentáveis (Artmann et al., 2019; Burton et al., 2003; Creutzig et al., 2015; Glaeser & Kahn, 2010). Uma das principais maneiras como a forma urbana afeta a sustentabilidade ambiental é por meio da sua influência sobre os padrões de mobilidade urbana (Cervero & Kockelman, 1997; Ewing & Cervero, 2010; Lohrey & Creutzig, 2016). Diversos estudos analisam, por exemplo, em que medida cidades mais compactas, com maior densidade populacional e com maior mix de uso do solo entre áreas residenciais e de outros tipos poderiam proporcionar padrões de viagem com menor consumo de energia e emissão de poluentes (Banister et al., 1997; Y. Liu et al., 2014; McCarty & Kaza, 2015), além de maior uso de modos de transporte ativos e menor dependência do automóvel (Buehler, 2011; Guerra & Li, 2021). No entanto, a maioria desses estudos é baseada em análises estatísticas que não permitem destacar os canais causais pelos quais a forma urbana impacta padrões de mobilidade (Crane, 2000; C. Liu & Shen, 2011; Næss, 2015). Além disso, existem poucas evidências sobre a relação entre forma urbana e mobilidade sustentável no Brasil (A. N. R. da Silva et al., 2007), um dos países mais populosos e urbanizados do sul global (UN-Habitat, 2020).

Neste estudo, nós analisamos como a organização espacial das cidades brasileiras impacta a sustentabilidade ambiental da mobilidade urbana. Nós utilizamos modelos de regressão para analisar como o consumo de energia no transporte individual motorizado nas 182 maiores áreas urbanas é influenciado por diferentes características da morfologia urbana (densidade populacional, mix de uso do solo, compacidade e fragmentação do tecido urbano, além do grau de conectividade e sinuosidade da rede viária). As variáveis incluídas nas regressões foram selecionadas com base em um Grafo Acíclico Dirigido (*Directed Acyclic Graph*, DAG) (Pearl, 1995) que propomos a partir de extensa revisão da literatura. A construção desse DAG permite mapear os canais de causalidade entre diversas características de forma urbana e o nível de consumo de energia na mobilidade, além de evitar a inclusão de variáveis que causem viés de colisão ou confusão. O estudo combina indicadores de forma urbana calculados a partir de dados de imagem de satélite, registros administrativos e dados censitários. O consumo de energia na mobilidade é estimado para o transporte individual motorizado a partir de dados sobre volume de combustível (gasolina e etanol) vendido nos municípios do país. Essa *proxy* para o consumo de

energia reflete em que medida a mobilidade urbana de uma cidade depende do transporte motorizado individual e está associada ao tamanho da sua pegada ambiental em termos de nível de emissões.

Existe um amplo entendimento na literatura de que a forma urbana das cidades cria condições que podem restringir ou ampliar as capacidades das pessoas de adotarem padrões de mobilidade urbana mais sustentáveis (C. Silva et al., 2014). Diversos estudos anteriores apresentam algum tipo de diagrama que nos ajuda a compreender como a forma urbana poderia influenciar padrões de viagens, nível de consumo energético ou de emissões de CO2 (X. (Jason) Cao et al., 2019; Ding et al., 2018; S. Song et al., 2016; Travisi et al., 2010). No entanto, a maioria desses diagramas são construídos para análises desagregadas no nível de comportamento de indivíduos, o que não permite comparação entre cidades. Além disso, os modelos apresentados na literatura são, via de regra, versões simplificadas que reduzem a forma urbana das cidades a apenas uma ou duas dimensões morfológicas. Por fim, a maior parte dessa literatura seleciona as variáveis incluídas em análises de regressão sem levar em consideração os possíveis caminhos causais e viéses explicitados por estes diagramas ou outros modelos teóricos (Crane, 2000; C. Liu & Shen, 2011).

O presente estudo contribui para a literatura ao propor um DAG relacionando forma urbana, padrão de viagens das pessoas e consumo energético na escala metropolitana. O estudo ilustra ainda como o DAG permite uma seleção mais criteriosa de variáveis de controle para modelos de regressão, isolando os canais por meio dos quais a forma urbana afeta o consumo de energia e a mobilidade. Este trabalho também é o primeiro estudo de larga escala no Brasil a trazer evidências sobre a relação entre diversas dimensões de forma urbana e mobilidade urbana sustentável considerando as 182 maiores aglomerações urbanas no país.

O restante do trabalho é dividido da seguinte maneira. A seção dois traz uma revisão da literatura sobre forma urbana e mobilidade sustentável, e apresenta uma sistematização das relações entre variáveis de forma urbana e padrões de viagens. A seção três apresenta em detalhes os dados e métodos utilizados neste trabalho, incluindo detalhes sobre indicadores de forma urbana e consumo de energia, a construção do DAG e especificação do modelo de regressão. A seção quatro traz os resultados, com um breve contexto histórico de como o crescimento e a forma urbana das cidades brasileiras evoluiu entre 1990 e 2015 e apresenta os resultados das análises de regressão. Por fim, a seção cinco contém as considerações finais, indicando reflexões para políticas públicas e para agenda futura de pesquisa.

2. REVISÃO DE LITERATURA

Existe uma extensa literatura sobre como a organização espacial das cidades influencia a mobilidade urbana (Ewing & Cervero, 2010; Lohrey & Creutzig, 2016; Stevens, 2017). Por exemplo, diversos estudos analisam como a forma urbana impacta o comportamento de viagem das pessoas, seja induzindo percursos mais curtos/longos (Ewing et al., 2018; Lee e Lee, 2020; Van de Coevering e Schwanen, 2006; Liu e Shen, 2011), escolha do modo de transporte (Bento et al., 2005; Buehler, 2011; Guerra & Li, 2021) ou tempos despendidos no trajeto (Jun, 2020; Muñis e Galindo, 2005). Alguns trabalhos analisam ainda como o desempenho e a viabilidade econômica de sistemas de transporte público são afetados pela densidade populacional e mix de uso do solo (Cooke & Behrens, 2017; S. Lee & Bencekri, 2021). Uma questão amplamente abordada na literatura tem sido como a forma urbana das cidades afeta a sustentabilidade dos sistemas de transporte em termos de poluição (Kang et al., 2019; C. Lee, 2020; McCarty & Kaza, 2015), emissões de CO_2 (Lee e Lee, 2020; Liu et al., 2014) e consumo energético (Silva et al., 2007; Zhato et al., 2017; Liu e Shen, 2011).

Em linhas gerais, essa literatura pode ser dividida em dois grandes grupos: um que privilegia análises desagregadas principalmente na escala local (intra-urbana); outro que foca mais em análises agregadas e em escala regional (metropolitana) (Handy, 1996; Milakis et al., 2015). Os estudos do primeiro grupo são os mais comuns. Eles analisam como o comportamento de viagem dos indivíduos (e.g. posse de automóveis, escolha de modo de transporte, distâncias percorridas, consumo de energia etc) é afetado por características do ambiente construído (*built environment*) em suas áreas de residências (C. Liu & Shen, 2011; Muñiz & Galindo, 2005). Dentre as características mais comumente analisadas, incluem-se a densidade residencial, mix de uso do solo, distância até o centro da cidade e oferta de transporte público (Bento et al., 2005; S. Lee & Lee, 2020; Van Acker & Witlox, 2010; van de Coevering & Schwanen, 2006). Muitos desses estudos utilizam modelos de regressão multinível para captar como o padrão de viagens das pessoas é afetado tanto por características do ambiente construído local quanto por características da forma urbana na escala metropolitana. (Ewing et al., 2015; Guerra & Li, 2021; Hong et al., 2014; S. Lee & Lee, 2020; Zhao et al., 2017).

Estudos nessa escala de análise requerem dados mais detalhados, tanto sobre indivíduos ou domicílios quanto sobre as características urbanas para quarteirões ou bairros. Um desafio

importante nessa abordagem é a endogeneidade gerada pela (auto-)seleção de moradores por seus respectivos bairros. Assim, não é possível saber a direção causal da relação entre preferências locacionais e perfis de viagem: as características de um bairro afetam os comportamentos de viagem, mas as preferências de viagens certamente também afetam escolhas de local de moradia (Handy et al., 2005). Um crescente número de estudos têm conseguido tratar esse problema utilizando dados longitudinais (De Vos et al., 2021; Handy et al., 2006) e variáveis instrumentais (Boarnet & Sarmiento, 1998; Hong & Shen, 2013; Ihlanfeldt, 2020). Em síntese, esses trabalhos encontram que, mesmo após controlar as análises por atitudes/preferências, auto-seleção (X. (Jason) Cao et al., 2009; X. Cao & Yang, 2017; Handy et al., 2005, 2006), e por dependência espacial (Hong & Shen, 2013), pessoas que moram em bairros com maior densidade e mix de uso do solo, maior oferta de transporte público, e ambientes caminháveis tendem a usar menos o automóvel e fazer mais viagens por modos mais sustentáveis, emitindo menos CO_2.

O segundo grupo de estudos, que analisa a relação entre forma urbana e mobilidade em escala espacial mais agregada, costuma fazer análises comparativas entre cidades ou bairros para examinar como características da estrutura das cidades (e.g. manchas urbanas mais compactas ou espraiadas, contíguas ou fragmentadas etc.) afetam o desempenho de seus sistemas de transporte em termos de quantidade média de quilômetros percorridos por pessoa (Ewing et al., 2014), distribuição modal (Hamidi & Ewing, 2014; Saeidizand et al., 2022), ou emissão de CO_2 (Castells-Quintana et al., 2021). Por exemplo, num estudo analisando 27 capitais brasileiras e outros 184 municípios com mais de 20 mil habitantes no estado de São Paulo, Silva et al. (2007) encontraram que cidades mais densas e mais compactas tiveram menor consumo de energia per capita no transporte urbano. Esse resultado é semelhante àquele encontrado por (Creutzig et al., 2015) em uma análise comparativa internacional de 284 cidades, onde grande parte da variação do consumo de energia no transporte é explicada por variações nos níveis de densidade populacional e preço de combustíveis.

Um aspecto marcante nessa literatura é a variedade de características de estrutura urbana consideradas e de indicadores utilizados para medir cada dimensão (Ewing & Cervero, 2010; Stevens, 2017). Apesar de divergências metodológicas, há grande convergência entre os resultados encontrados. As evidências acumuladas sugerem que cidades mais densas, com maior mix de uso do solo, mais compactas e com maior conectividade da rede de transporte são mais sustentáveis — com menor consumo de energia, emissão de CO_2 e dependência do automóvel (Ewing & Cervero,

2010; Stevens, 2017).

A maioria desses trabalhos, no entanto, é baseada apenas em correlações ou modelos que não identificam efeitos causais (Næss, 2015). Há um crescente número de estudos que usam Análise de Trajetórias (*"causal path analysis"*) (Travisi et al., 2010) e Modelos de Equações Estruturais para analisar a relação entre forma urbana e mobilidade (Bagley & Mokhtarian, 2002; De Vos et al., 2021; Ding et al., 2018; Ewing et al., 2014; Van Acker & Witlox, 2010). Embora a aplicação desses tipos de modelos também não garanta captar efeitos causais (Bollen & Pearl, 2013), esses estudos dão importante contribuição ao explicitar que os canais de causalidade, pelos quais a forma urbana impacta a sustentabilidade da mobilidade urbana, se dão por meio de sua influência sobre o padrão de viagens das pessoas.

Se, por um lado, a forma urbana é o resultado de um acumulado de políticas de planejamento e decisões individuais no longo prazo, por outro, ela age também no curto e médio prazo como um elemento estrutural de contexto, que influencia decisões individuais/familiares sobre seus comportamentos de viagem e escolha de moradia (Næss, 2015). Diferentes características da organização espacial das cidades influenciam diferentes aspectos das decisões de mobilidade ao criarem ambientes urbanos mais ou menos propícios para determinados padrões de viagens e meios de transporte (C. Silva et al., 2014).

3. MÉTODOS

O método de pesquisa deste estudo foi dividido em quatro etapas. Primeiramente, calculamos indicadores que captam diferentes dimensões de forma urbana a partir do processamento de dados de satélite, da estrutura da malha viária e registros administrativos. Em seguida, utilizamos Análise Fatorial para identificar quais dimensões morfológicas têm maior associação entre si. Esse passo permite diminuir redundância na análise de indicadores. Na terceira etapa, nós elaboramos Grafos Acíclicos Dirigidos para formalizar as relações causais teoricamente esperadas entre variáveis de forma urbana e consumo energético na mobilidade. A análise pormenorizada dos DAGs nos permite avaliar quais são as variáveis de controle necessárias para estimar os efeitos de interesse, além de quais modelos alternativos deveriam levar a resultados estatisticamente semelhantes, sob a hipótese da correta especificação da rede de relações causais. Na quarta etapa, estimamos

modelos de regressão, tomando os indicadores de forma urbana como variáveis independentes e o consumo de energia per capita em viagens no transporte individual motorizado como variável dependente.

Cada uma dessas etapas é descrita nas subseções a seguir. Antes, no entanto, as seções 3.1 e 3.2 apresentam a definição de áreas urbanas e as bases de dados utilizadas neste estudo. Todos os códigos computacionais em R utilizados neste trabalho para download e análise de dados estão disponíveis no repositório <<https://github.com/ipeaGIT/urbanformbr>>.

3.1. Áreas de Concentração Urbana: a unidade de análise

Uma primeira questão essencial em qualquer pesquisa desse tipo é a delimitação das unidades de análise, ou seja, onde começa e termina cada área urbana. Por conta da dinâmica funcional e espacial das atividades econômicas, muitas vezes as áreas urbanas funcionais ultrapassam as fronteiras político-administrativas dos municípios. Assim, não seria adequado definir as unidades de análise desse modo. As regiões metropolitanas oficiais do Brasil também não parecem ser uma escolha adequada, pois não são definidas com base numa única metodologia consistente. Além disso, há pouca transparência sobre como critérios técnicos e políticos influenciam na delimitação dessas áreas no país, o que compromete a comparabilidade entre elas. Estudos anteriores propuseram metodologias de delimitação de áreas urbanas funcionais a partir de dados de imagens de satélite (Angel et al., 2016; Dijkstra et al., 2019, 2021; Mahtta et al., 2019; Moreno-Monroy et al., 2021). No entanto, essas metodologias são propostas para todo o globo terrestre ou grande regiões, e acabam não contemplando as particularidades do contexto de cada país.

As unidades de análise empregadas neste estudo partem do conceito de Arranjos Populacionais, recortes territoriais de agregação de municípios brasileiros construídos com base na integração populacional "devido aos movimentos pendulares para trabalho ou estudo, ou devido à contiguidade entre as manchas urbanizadas principais" (IBGE, 2016, p. 22). Mais especificamente, concentramos nossas análises nas médias e grandes Áreas de Concentração Urbana (ACU), municípios isolados ou arranjos populacionais com mais de 100 mil habitantes que refletem o médio e alto escalão da urbanização brasileira. As ACUs foram escolhidas como unidades de análise pois elas nos parecem ser a definição mais próxima de áreas urbanas funcionais existentes no Brasil. Além disso, elas são relativamente mais comparáveis, uma vez que sua delimitação segue

uma mesma metodologia para todo país. Nesse estudo, as expressões áreas de concentração urbana, aglomerações urbanas e cidades são utilizadas como sinônimos.

Segundo o IBGE, existiam 185 aglomerações urbanas no Brasil com mais de 100 mil habitantes considerando a população de 2010. Existem três aglomerações localizadas em áreas de fronteira internacional e conurbadas com áreas urbanas em países vizinhos[e]. Essas áreas foram excluídas das nossas análises por falta de dados que dêem a visão completa sobre sua dinâmica urbana, econômica e de mobilidade em ambos os lados da fronteira.

Assim, este trabalho investiga a dinâmica de forma urbana e mobilidade de 182 aglomerações urbanas no Brasil. Juntas, essas áreas continham, em 2010, aproximadamente 114 milhões de habitantes (58,2% da população do país) em um total de 635 municípios que ocupam apenas 6.1% do território brasileiro, mas que concentravam cerca de 77% do PIB nacional.

3.2. Dados

Consumo de energia no transporte urbano

A intensidade de uso de energia per capita no transporte urbano foi estimada a partir dos dados de consumo de combustível, disponíveis nos registros anuais da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP, 2021). Nós consideramos apenas o consumo de etanol hidratado e gasolina, uma vez que são os principais combustíveis utilizados nos deslocamentos por transporte individual motorizado (automóvel e motocicleta). Embora o combustível de óleo diesel pudesse trazer alguma informação sobre o consumo energético nos sistemas de transporte público, esse tipo de combustível também é muito utilizado por veículos pesados como caminhões, tratores, etc. que trafegam em grande parte fora de áreas urbanas. Por isso, o consumo de óleo diesel não foi considerado neste estudo. Isso gera uma limitação da pesquisa, uma vez que nossas estimativas ignoram o consumo de energia nos sistemas de transporte público e veículos urbanos à diesel de pequeno e médio porte. Por outro lado, garante que nossa análise se refere especificamente às áreas urbanas.

Para estimar o consumo de energia total, nós utilizamos como base os dados do volume de

[e] ACUs: Internacional de Uruguaiana/Brasil (RS); Internacional de Foz do Iguaçu/Brasil - Ciudad del Este/Paraguai (PR); e Internacional de Corumbá/Brasil (MS).

etanol hidratado e gasolina automotiva vendidos em cada município no ano de 2010. Essa simplificação tem o pressuposto de que todo combustível vendido em uma aglomeração urbana foi consumido naquela área. O consumo energético é estimado a partir de dados de volume consumido (V), poder calorífico inferior (PCI) e densidade (ρ) de cada combustível, conforme expressão:

$$Energia\ total\ = Energia\ etanol\ hidratado\ +\ Energia\ gasolina \quad (1)$$

$$Energia\ total\ =\ (V_e \cdot\ \rho_e\ \cdot PCI_e)\ +\ (V_g \cdot\ \rho_g\ \cdot PCI_g)\,, \qquad (2)$$

onde os índices e e g indicam etanol hidratado e gasolina, respectivamente. A unidade de energia é Tonelada Equivalente de Petróleo (TEP), que equivale a aproximadamente 41,85 GJ (Giga Joules). Os valores de referência utilizados na estimativa foram: densidade etanol = 806 kg/m³, densidade gasolina = 742 kg/m³, PCI etanol = 6300 kcal/kg, PCI gasolina = 10400 kcal/kg (EPE, 2020).

O consumo de energia total per capita foi calculado dividindo-se a quantidade de energia total consumida em 2010 pela população registrada no Censo Demográfico de 2010.

Dados socioeconômicos

As variáveis sobre as características sociais, econômicas e demográficas da população residente nas áreas urbanas foram obtidas a partir dos dados da amostra do Censo Demográfico de 2010 (IBGE, 2010). Foram estimados indicadores referentes ao tamanho da população; à proporção de domicílios pertencentes a áreas classificadas como urbanas; à média da renda domiciliar *per capita*; à razão de dependência demográfica (soma das populações com idade menor do que 15 anos e maior do que 64 anos dividida pela soma da população em idade economicamente ativa entre 15 e 64 anos de vida); e à proporção de pessoas com alta escolaridade (definida como pessoas com ensino superior completo) [f].

[f] Com exceção da proporção de domicílios urbanos, todos os indicadores derivados do censo demográfico foram calculados considerando-se apenas a população residente em áreas urbanas.

Forma urbana

Os indicadores de forma urbana foram calculados a partir de duas bases de dados. Um primeiro grupo de indicadores capta aspectos da mancha urbana e foram calculados a partir das bases de dados de ocupação urbana do *Global Human Settlement Layer* (GHSL), produzidos pela Comissão Europeia (Florczyk et al., 2019). O segundo grupo capta características morfológicas da rede viária e foram calculados com dados do OpenStreenMap (OSM). Os indicadores de forma forma serão detalhados adiante na seção 3.4.

Os dados do GHSL são gerados por meio de uma estrutura automatizada de processamento e classificação de dados de imagens de satélites e dados censitários (Corbane et al., 2019a). As informações contemplam os anos de 1975, 1990, 2000, 2014 e 2015, sendo organizadas em grades de raster com resolução de 1 km x 1 km. Para cada célula das grades, estão disponíveis estimativas de população residente, proporção da mancha urbana e índice de cobertura (indicando qual proporção daquela célula está coberta por construções, como casas, edifícios, etc).[g].

O uso das bases do GHSL é justificado por algumas razões. Em primeiro lugar, é necessário uma fonte de dados que cubra diversos anos. Em segundo, os dados devem ter resolução espacial relativamente refinada, que possibilite o delineamento de áreas urbanas de portes distintos. Por fim, esses dados devem captar a heterogeneidade e variabilidade do grau de urbanização de áreas urbanas. Os dados do GHSL são os únicos que preenchem todos esses requisitos dentre as bases comumente usadas para medir expansão urbana (He et al., 2019). Suas informações permitem mensurar o crescimento da mancha e da população urbana desde 1975 e com uma resolução espacial adequada e mais eficiente na captação da variabilidade do que os dados de luzes noturnas comumente utilizados em outros estudos na literatura (Mahendra & Seto, 2019; Mahtta et al., 2019). A base de dados do GHSL de 1975, no entanto, não cobre boa parte da região norte e nordeste do Brasil (Corbane et al., 2019b). Por esse motivo, nossas análises históricas começam somente a partir dos anos 1990.

[g] Na metodologia do projeto GHSL, o índice de cobertura do solo se baseia no conceito de áreas construídas (*built-up areas*), definidas como áreas - unidades espaciais - em que edificações humanas podem ser encontradas (Pesaresi et al., 2013). Tais edificações, por sua vez, são entendidas como quaisquer construções acima do solo, dotadas de cobertura e erguidas ou utilizadas para o abrigo de bens, pessoas ou para a produção de bens e serviços econômicos. Não estão incluídas na definição, portanto, construções subterrâneas ou redes viárias.

Neste estudo, nós consideramos como área urbanizada todas as células que possuíam um índice de cobertura de pelo menos 20%, formando as extensões urbanas de cada unidade de análise. Para determinar esse limite mínimo, nós comparamos o tamanho de cada área urbanizada oficialmente estimada pelo IBGE em 2015 (IBGE, 2017) com o tamanho da área urbanizada estimada a partir dos dados do GHSL, considerando diferentes valores do índice de cobertura. Usando análises de sensibilidade, optou-se pela utilização do ponto de corte de 20%, por gerar as menores diferenças de total de área urbanizada para o conjunto das 182 áreas de concentração urbana. A Figura 1 ilustra o resultado da definição desse limiar, mostrando a evolução das áreas urbanizadas das aglomerações urbanas de Belo Horizonte e de Salvador entre 1990 e 2014. Essas grades raster de mancha urbana definidas segundo o limiar de 20% de taxa de cobertura servem como base para o cálculo dos diferentes indicadores de forma urbana, como detalhado na seção 3.4 adiante.

Figura 1. Área urbanizada da área de concentração urbana de Belo Horizonte e Salvador, 1990, 2000 e 2014.

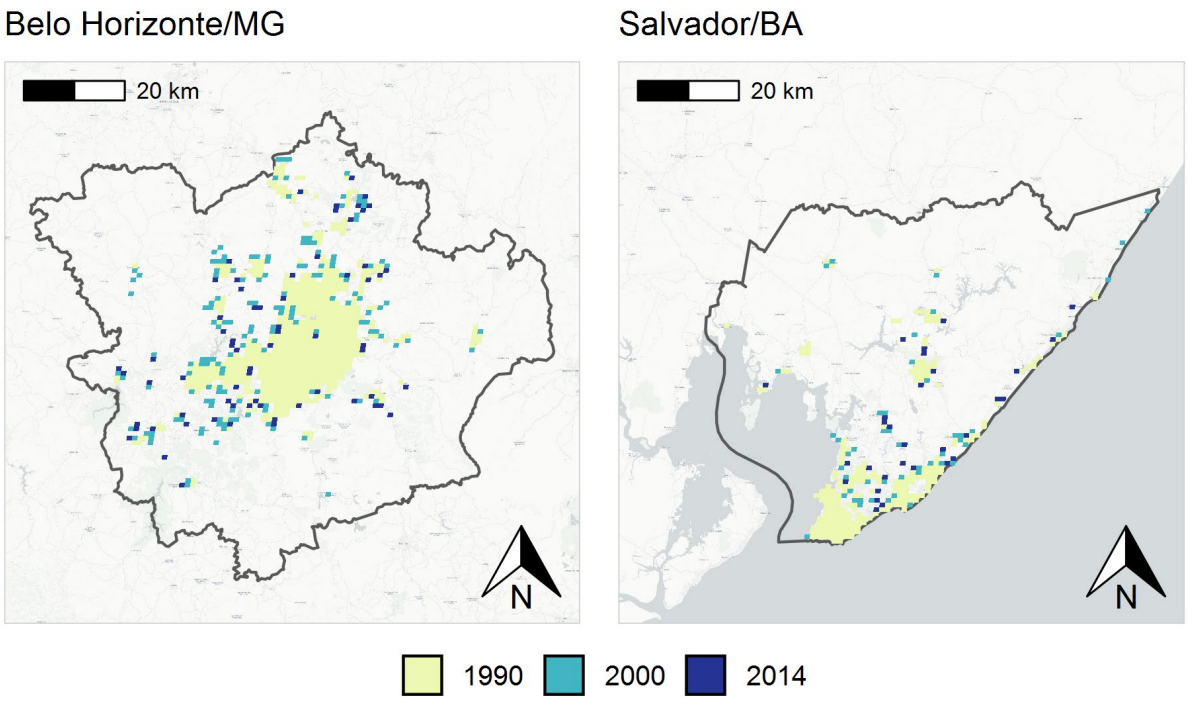

Uso do solo

Uma importante dimensão da forma urbana é a organização espacial e a co-localização dos diferentes tipos de uso do solo. Para captar a organização de uso do solo das cidades brasileiras nós utilizamos os dados de 2010 do Cadastro Nacional de Endereços para Fins Estatísticos (CNEFE). Os dados de estabelecimentos e endereços do CNEFE foram coletados pelo IBGE durante o censo demográfico e contêm informações de uso do solo para todos os endereços do Brasil, em formato tabular. Para cada endereço registrado no CNEFE existem informações em dois níveis de detalhe: categórico e descritivo (i.e. uma resposta aberta textual). A coluna de dados categóricos classifica os usos do solo em sete categorias, conforme lista abaixo. O campo descritivo contém informações adicionais sobre o uso de cada endereço, conforme preenchidas pelo recenseador durante a realização do Censo Demográfico. Neste estudo nós trabalhamos com os dados categóricos. As seguintes categorias de uso do solo estão disponíveis nos dados do CNEFE:

1) Domicílio particular,
2) Domicílio coletivo,
3) Estabelecimento agropecuário,
4) Estabelecimento de ensino,
5) Estabelecimento de saúde,
6) Estabelecimento de outras finalidades (comerciais, industriais, serviços, etc.), e
7) Edificação em construção.

Para análises de forma urbana, foi necessário geolocalizar os endereços do CNEFE para captar a distribuição espacial dos diferentes tipos de uso do solo, pois essa base de dados somente traz informações das coordenadas geográficas das atividades localizadas em áreas rurais. Para geolocalizar os endereços urbanos, executamos um procedimento em duas etapas, descritas a seguir.

A primeira etapa de geolocalização utilizou a base de dados de Faces de Logradouros, também produzida pelo IBGE para o Censo Demográfico de 2010. Essa base de dados espacial contém o desenho de cada face de quarteirão localizado em áreas urbanas. Cada face de quarteirão possui um identificador único e que possui correspondência com os dados dos CNEFE, o que

permite identificar as coordenadas geográficas dos estabelecimentos e endereços do CNEFE. Isso não permite identificar a localização exata do endereço dentro do quarteirão, porém permite inferir a localização espacial do endereço com precisão suficiente para esse estudo. Entretanto, a base de faces de logradouros de 2010 não é completa, deixando de fora áreas importantes de algumas cidades. No total, 70% dos endereços das áreas urbanas em estudo puderam ser geolocalizados nesta primeira etapa.

Numa segunda etapa, os endereços remanescentes foram geolocalizados utilizando o software ArcGIS e a base de dados StreetMap Premium, da ESRI. Os resultados dessa etapa foram validados através da comparação das coordenadas do endereço obtidas do StreetMap Premium com o polígono do setor censitário ao qual o endereço pertence (informação disponível no CNEFE). Endereços localizados a uma distância de até 500 metros dos limites do respectivo setor censitário foram considerados válidos e utilizados no estudo, enquanto o restante foi descartado. Ao final do processo, 22% dos endereços puderam ser encontrados com o uso do StreetMap Premium, alcançando um total de 92% de endereços geolocalizados com sucesso. Com essas informações foi possível identificar quantos casos do CNEFE, segundo tipo de uso do solo, estão contidos dentro de cada célula raster de 1 km x 1 km do GHSL.

É importante destacar algumas limitações para o uso de dados do CNEFE para análises de uso do solo. Embora o CNEFE seja a única fonte pública de dados no Brasil com informação detalhada sobre a quantidade de endereços, ele não permite separar, por exemplo, atividades comerciais, industriais e de serviços (todos classificados na categoria 6 - estabelecimentos de outras finalidades). Além disso, ele não traz informação sobre a intensidade de atividade em cada endereço. Assim, o CNEFE não faz distinção, por exemplo, entre um posto de saúde com 50 funcionários e um hospital com 500 funcionários.

Frota de veículos

As idades médias das frotas de veículos (automóveis e motocicletas) nas áreas de concentração urbana foram estimadas a partir da base de dados do Registro Nacional de Veículos Automotores (RENAVAM), considerando os registros de fevereiro de 2020. Esses registros apresentam o número total de marcas/modelos de veículos conforme ano de fabricação, município e estado (UF) de registro. Além disso, de forma complementar, foi utilizada base de dados do RENAVAM de marcas/modelo de veículos conforme

categoria (ex., automóvel ou motocicleta) (*Estatísticas - Frota de Veículos - RENAVAM*, 2021). A idade média da frota foi calculada a partir do número total de registros observados por categoria no ano de 2020. Isso porque não existem registros de idade média conforme categoria no ano de 2010. Embora a idade média da frota de cada município possa ter se alterado entre 2010 e 2020, é razoável assumir que as diferenças entre municípios tenham se mantido muito próximas, uma vez que a correlação entre número total de veículos dos municípios em 2010 e 2020 é alta, de 0.996.

Rede viária

Neste estudo nós também utilizamos dados da malha de ruas para calcular indicadores de forma urbana a partir da configuração da rede viária. Esses dados foram obtidos do OpenStreetMap (OSM) através do pacote de Python OSMnx (Boeing, 2017). O pacote OSMnx permite automatizar o download das bases de dados de acordo com os limites geográficos das aglomerações urbanas, criar redes de transportes topologicamente corrigidas (com ajustes nas geometrias dos segmentos de vias e interseções) e possibilita gerar análises métricas e topológicas das redes de transporte. Por se tratar de uma base de dados colaborativa com atualização voluntária pela comunidade, é esperado que a cobertura dos dados do OSM no Brasil seja melhor nos dias de hoje do que no ano de 2010, principalmente nas cidades de médio e pequeno porte. Por isso, optamos por utilizar os dados do OSM de outubro de 2021. Embora fosse importante utilizar informações sobre as características das redes de transporte público, esses dados não foram incluídos no estudo pois não estão publicamente disponíveis para a maioria das cidades do Brasil.

Topografia

As características topográficas têm importante influência sobre a ocupação e o uso do solo, assim como sobre a dinâmica dos sistemas de transporte. Neste estudo, nós utilizamos dados de topografia da *Shuttle Radar Topography Mission* (SRTM) da NASA, referentes ao ano de 2000 e com resolução espacial de 1 arco-segundo (aproximadamente 30 metros) (NASA JPL, 2013). Os dados correspondem a um modelo digital de elevação (*digital elevation model* - DEM), isto é, uma representação espacial da topografia da superfície terrestre em formato raster.

Nós calculamos a declividade média das áreas urbanizadas para cada uma das 182 áreas de concentração urbana como um indicador síntese da sua topografia. O indicador foi calculado considerando-se uma matriz de vizinhança de tipo rainha composta pela grade de dados raster de

topografias (com oito vizinhos de primeira instância) e utilizando-se o algoritmo desenvolvido por Horn (1981).

3.3. Tipos de crescimento urbano e ocupação do solo

O crescimento urbano pode ocorrer seguindo diferentes padrões de ocupação do espaço, estando associado a maiores ou menores impactos ambientais em termos de custos de provisão de serviços públicos e de geração de viagens (Camagni et al., 2002). Diversos estudos propuseram tipologias sobre como uma nova área de expansão urbana poderia ser classificada em relação à área urbana pré-existente (Batty, 2018; Camagni et al., 2002; Inostroza et al., 2013; Mahtta et al., 2019). Apesar de pequenas diferenças entre as classificações propostas, todas convergem para quatro tipos de crescimento urbano:

1) **Adensamento urbano** (*densification*): crescimento populacional dentro de áreas urbanas já consolidadas;
2) **Preenchimento urbano** (*infill*): preenchimento de vazios urbanos cercados de áreas já consolidadas;
3) **Espalhamento urbano** (*sprawl*), podendo ocorrer por duas maneiras:
    a) Extensão (*extension*): extensão da área urbanizada com crescimento da franja urbana em áreas contíguas à áreas urbanas preexistentes;
    b) *Leapfrog*: crescimento urbano fragmentado, desconectado de áreas urbanas preexistentes e atuais.

Para identificar qual proporção do crescimento das cidades brasileiras ocorreu conforme cada um dos tipos acima, nós analisamos o crescimento urbano entre 1990 e 2014 a partir dos dados do GHSL. A mancha urbana que já existia em 1990 foi classificada como área urbana consolidada. Todo crescimento populacional observado entre 1990 e 2014 e as células de raster de 1 km de 2014 foram classificadas tomando-se aquela área urbana consolidada de 1990 como referência. Assim, todo crescimento populacional que ocorreu dentro da área consolidada foi classificado como crescimento do tipo “adensamento”, que contribui para o aumento da densidade populacional da

área urbana[h]. Foi considerado como "preenchimento" aquele crescimento populacional que ocorreu numa célula que ainda não era urbanizada em 1990, mas que era cercada por pelo menos quatro células vizinhas (*rook contiguity*) urbanizadas naquele ano. O crescimento populacional em novas áreas urbanas de 2014 localizados a uma distância buffer de até 1 km da área consolidada de 1990 foi classificado como crescimento de "extensão"— que expande a mancha urbana da cidade. Esse limite de 1 km foi escolhido para manter coerência com a metodologia oficial do IBGE (IBGE, 2016) na delimitação de áreas urbanizadas. Finalmente, foi considerado como tipo "fragmentação" (*leapfrog*) todo crescimento populacional que ocorreu nas novas áreas urbanas captadas em 2014 e que estavam a mais de 1 km de distância das áreas urbanas consolidadas e de extensão. A Figura 2 ilustra para a área de concentração urbana de Porto Alegre a distribuição espacial dos tipos de crescimento urbano entre 1990 e 2014.

Figura 2: Ilustração dos tipos de crescimento urbano da área de concentração urbana de Porto Alegre entre 1990 e 2014.

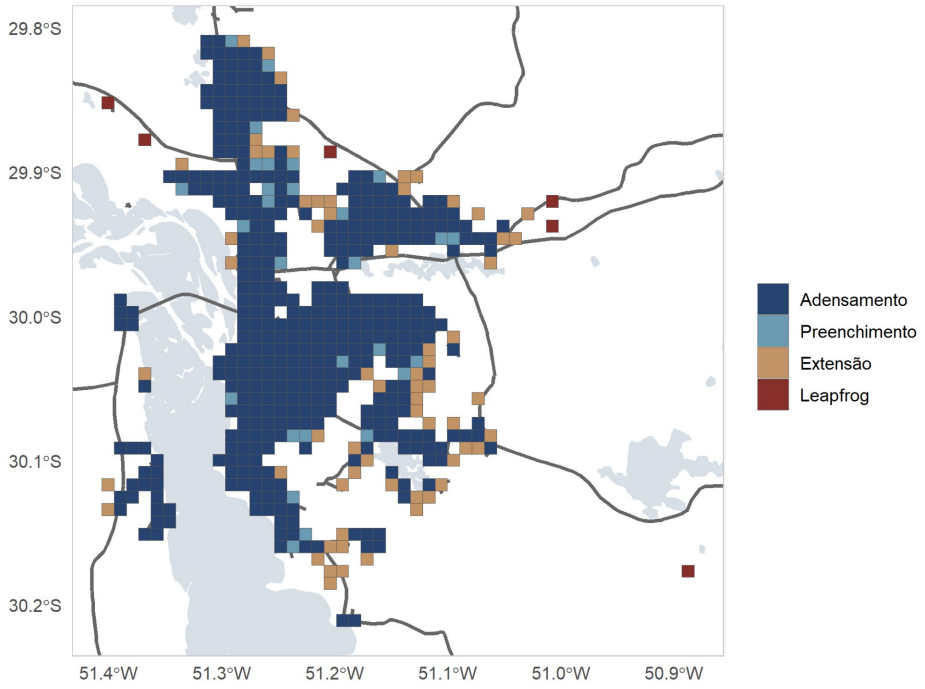

[h] Importante esclarecer que adensamento urbano não implica necessariamente em verticalização e vice-versa (Angel et al., 2016). É possível aumentar o adensamento de uma determinada área sem verticalização, por exemplo, elevando-se o número de edifícios geminados e com menor recuo, o número de unidades domiciliares de menor tamanho, ou a quantidade de moradores por domicílio. No limite, também é possível que a verticalização de uma determinada área diminua a sua densidade se, por exemplo, um edifício baixo mas de alta densidade é substituído por um arranha-céu com menor número de apartamentos maiores, com menos moradores etc.

3.4. Indicadores de forma urbana

A seguir, nós descrevemos em mais detalhes os indicadores utilizados para mensurar algumas das principais dimensões de forma urbana abordadas na literatura: densidade experienciada, compacidade, contiguidade e mix de uso do solo. Além disso, nós incluímos outros indicadores calculados a partir da configuração da rede viária: centralidade por proximidade, densidade de interseções e sinuosidade.

Densidade experienciada

Densidade populacional é uma das dimensões mais importantes que expressa a forma de ocupação do território. Usualmente, a densidade é calculada simplesmente pela razão entre população habitante e a área em questão (e.g. medida em habitantes por km²). Tal metodologia supõe uma homogeneidade na ocupação do espaço ao longo de todo território, o que é particularmente problemático para cidades grandes caracterizadas por diferentes regimes de uso do solo. Para contornar essa limitação, nós utilizamos neste trabalho o indicador de "densidade experienciada" (Duranton & Puga, 2020; Henderson et al., 2019; Roca & Puga, 2017). Esse indicador busca captar a densidade local que seria experienciada cotidianamente pelas pessoas durante seus deslocamentos num raio próximo ao seu local de residência.

Para calcular a densidade experienciada, nós utilizamos os dados de estimativa populacional do GHSL organizados em um raster com células de 1 km x 1 km. Para cada célula, definimos um raio de 2 km a partir do centróide e calculamos a densidade populacional dentro desta área. Em seguida, calculamos a média das densidades ponderada pela população de cada célula de referência. A escolha do raio do círculo é um tanto arbitrária. Estudos anteriores utilizaram raios que variaram entre 1 e 10 km (Duranton & Puga, 2020; Henderson et al., 2019; Roca & Puga, 2017). Nós optamos por um raio próximo ao limite inferior pois nossa amostra inclui áreas urbanas muito pequenas e, nesses casos, medidas com raios maiores acabam sendo enviesadas por um efeito de borda (a ausência de população na borda externa da cidade gera uma baixa densidade experienciada).

Compacidade

Cidades mais compactas concentram suas atividades em um espaço mais reduzido do território, aumentando assim a proximidade entre pessoas, empregos e oportunidades. De acordo com a literatura revisada na seção 2, cidades mais compactas reduzem a necessidade de longas viagens de seus habitantes, consequentemente reduzindo seu gasto energético. Por outro lado, esse ganho de eficiência tem um limite, e é possível que índices muito altos de compacidade possam causar deseconomias de escala e níveis altos de congestionamento, ocasionando maior gasto energético.

A compacidade capta o inverso do grau de espalhamento (*urban sprawl*) de uma área urbana. Tomando cada célula urbanizada do raster GHSL como uma unidade espacial, a compacidade foi definida como a soma do inverso das distâncias de cada célula para todas as demais, seguindo a equação:

$$Comp = \sum_{i}^{U} \quad \sum_{j \neq i}^{U} \quad \frac{1}{d(i,j)}, \qquad (3)$$

onde $Comp$ é o índice de compacidade, i e j indicam os índices de cada célula do raster da área urbanizada U e $d(i,j)$ indica a distância euclidiana entre os centróides das células i e j.

Essa medida é fortemente correlacionada ao tamanho da cidade, pois há uma área mínima que cada cidade pode ocupar dado seu tamanho. Para mitigar esse viés do tamanho, fizemos uma normalização de forma similar a Harari (2020), ou seja, dividindo-se a compacidade de cada ACU pela máxima compacidade que essa ACU poderia ter, caso ela tivesse um formato perfeitamente circular. Portanto, este indicador possui valores maiores para cidades mais compactas (até o máximo de 1), e valores menores para cidades mais dispersas. A expressão é dada por:

$$NComp = \frac{Comp}{max\ Comp_s}, \qquad (4)$$

onde $NComp$ é índice de compacidade normalizado, $Comp$ é o índice de compacidade absoluto, $max\ Comp_s$ é o valor máximo possível de compacidade de uma cidade de tamanho s.

Contiguidade

Medidas de contiguidade buscam identificar cidades com menor fragmentação e descontinuidade do tecido urbano. Essas descontinuidades podem ser causadas por diversos fatores, como: a) morfológicos, isto é, atributos físicos do terreno comumente relacionados a obstáculos geográficos (*e.g.* mar, rios ou montanhas); b) de planejamento urbano, que podem

favorecer a ocupação descontínua do território; e c) históricos, quando municípios próximos evoluem independentemente até formarem uma área funcional única porém descontínua.

Usando dados do GHSL, nós identificamos os *patches* (áreas urbanizadas formadas por células contíguas) que compõem cada área de concentração urbana. Em seguida, nós calculamos a proporção da área urbana ocupada pelo maior *patch* daquela cidade. Assim, quanto maior a proporção do maior *patch* em relação à cidade como um todo, maior o grau de contiguidade da área urbana. O valor máximo desse indicador é 1, indicando que 100% área urbana está contida em uma única mancha urbana contínua. O indicador de contiguidade é calculado a partir da seguinte equação:

$$Cont = \frac{max\ (PA)}{A}, \qquad (5)$$

onde: $max\ (PA)$ é a área do maior patch da ACU, e A é a área total da ACU.

Mix de uso do solo

Para calcular o nível de mix de uso do solo, nós utilizamos uma medida de dissimilaridade (Reardon & Firebaugh, 2002). Essa medida é amplamente utilizada em estudos de segregação residencial entre indivíduos pertencentes a grupos sociais diferentes, definidos em termos de renda, raça ou cor, religião, entre outros (Y. Song et al., 2013). Porém, a mesma lógica pode ser aplicada aos usos do solo urbanos, identificados pelas categorias disponíveis na base de dados do CNEFE (seção 3.2). A medida de dissimilaridade utilizada está descrita nas equações a seguir:

$$D = \sum_j^J \quad \sum_m^M \quad \frac{N_j}{2NI}\left|\tau_{jm} - \tau_m\right|, \qquad (6)$$

$$I = \sum_m^M \quad (\tau_m)(1 - \tau_m), \qquad (7)$$

onde D é o índice de dissimilaridade, N é o número total de endereços na ACU, J é o conjunto de células urbanas da ACU, M é o conjunto de categorias de uso do solo, N_j é o número total de endereços na ACU que pertencem à categoria de uso do solo j, τ_m é a proporção de endereços da ACU localizados na célula m, τ_{jm} é a proporção de endereços da categoria j da ACU localizados na célula m e I é o Índice de Interação de Simpson (White, 1986).

Os valores da medida de dissimilaridade variam entre 0 e 1, sendo que $D = 0$ indica que

cada unidade espacial contém a mesma proporção de usos do solo que as demais e $D = 1$ indica total segregação entre as atividades. Para facilitar a interpretação dos resultados deste estudo, nós definimos o indicador de mix de uso do solo como:

$$lum = 1 - D, \qquad (8)$$

onde lum é o indicador de mix de uso do solo (land use mix), e D é o índice de dissimilaridade da ACU. A partir dessa transformação, o indicador lum varia de 0 (total segregação de usos do solo) a 1 (total integração de usos).

Configuração da rede viária

Nós também calculamos indicadores de forma urbana captados a partir da configuração da rede viária. Topologicamente, a rede viária é formada por segmentos de via (*links*) e nós (*nodes*). Os links representam os trechos de via, enquanto os nós indicam intersecções viárias ou pontos de início/fim de via. Foram calculados três indicadores comumente utilizados na literatura de redes complexas para analisar a organização espacial e conectividade da malha de ruas (Boeing, 2020; Merchán et al., 2020; Porta et al., 2006): densidade de interseções, centralidade por proximidade e sinuosidade.

O indicador de **densidade de interseções** (*intersection density*) permite captar quão densa é a malha viária, refletindo a quantidade de vias e o tamanho dos quarteirões. Essa medida é calculada dividindo-se a quantidade de conexões da malha viária pela área total urbanizada da aglomeração urbana. Esse indicador é calculado de acordo com a equação:

$$D = \frac{N}{A}, \qquad (9)$$

onde D é a densidade de interseções, N é o total de interseções da rede viária, e A é a extensão da área urbana em km².

A **centralidade por proximidade** (*closeness centrality*) capta o grau de compacidade e conectividade de uma rede de transporte. Ela é calculada como o inverso da distância média entre cada nó para todos os demais nós (Freeman, 1979), de acordo com a equação:

$$C(u) = \frac{n-1}{\sum_{v=1}^{n-1} d(v,u)}, \qquad (10)$$

onde $C(u)$ é a centralidade por proximidade, $d(v,u)$ é o caminho mais curto entre os nós v e u; e n é o número de nós que podem alcançar u.

Para evitar que o indicador tenha viés de tamanho de cidade, foi realizada a sua normalização pelo tamanho da rede viária e então calculada a média para a ACU, conforme a equações:

$$NC(u) = \frac{C(u) - min(C(u))}{max(C(u)) - min(C(u))}, \qquad (11)$$

$$\underline{\boldsymbol{NC}}(\boldsymbol{u}) = \frac{\boldsymbol{\Sigma NC(u)}}{\boldsymbol{m}}, \qquad (12)$$

onde $NC(u)$ é a centralidade por proximidade normalizada, $min(C(u))$ é a centralidade por proximidade mínima, $max(C(u))$ é a centralidade por proximidade máxima, $\underline{NC}(u)$ é a média das centralidades por proximidade normalizadas, e m é o total de nós da malha viária.

Por sua vez, o indicador de **sinuosidade** (*circuity factor*) mede o quão sinuosas são as ruas de uma malha viária. Essa medida capta o quão "eficientes" ou curtas as viagens podem ser no sistema viário, e reflete o grau de organicidade de construção das vias, sendo influenciado, por exemplo, por características topográficas. O indicador é calculado dividindo-se a extensão de cada segmento de via pela distância euclidiana entre os seus nós inicial e final, conforme:

$$circuity = \frac{d_N(p,q)}{d_{L_2}(p,q)}, \qquad (13)$$

onde $d_N(p,q)$ é a distância em rede do nó de origem p e o nó de destino q e $d_{L_2}(p,q)$ é a distância euclidiana entre o nó de origem p e o nó de destino q.

Os três indicadores estão relacionados à eficiência com que as viagens podem ser realizadas entre diferentes pontos de uma rede. Cidades com malhas viárias mais densas, conectadas e compactas criam ambientes urbanos mais caminháveis e possibilitam que viagens sejam realizadas de forma mais direta e em distâncias mais curtas, aumentando a proximidade entre pessoas, empregos e oportunidades (Barrington-Leigh & Millard-Ball, 2015; Giacomin & Levinson, 2015; Sinnett & Williams, 2021).

Abaixo, a Figura 3 apresenta, apenas para fins de ilustração, alguns exemplos de aglomerações urbanas no Brasil que possuem valores altos e baixos em alguns dos principais indicadores de forma urbana calculados neste trabalho.

Figura 3. Exemplos de aglomerações urbanas com valores altos e baixos para diferentes indicadores de forma urbana. Brasil, 2015.

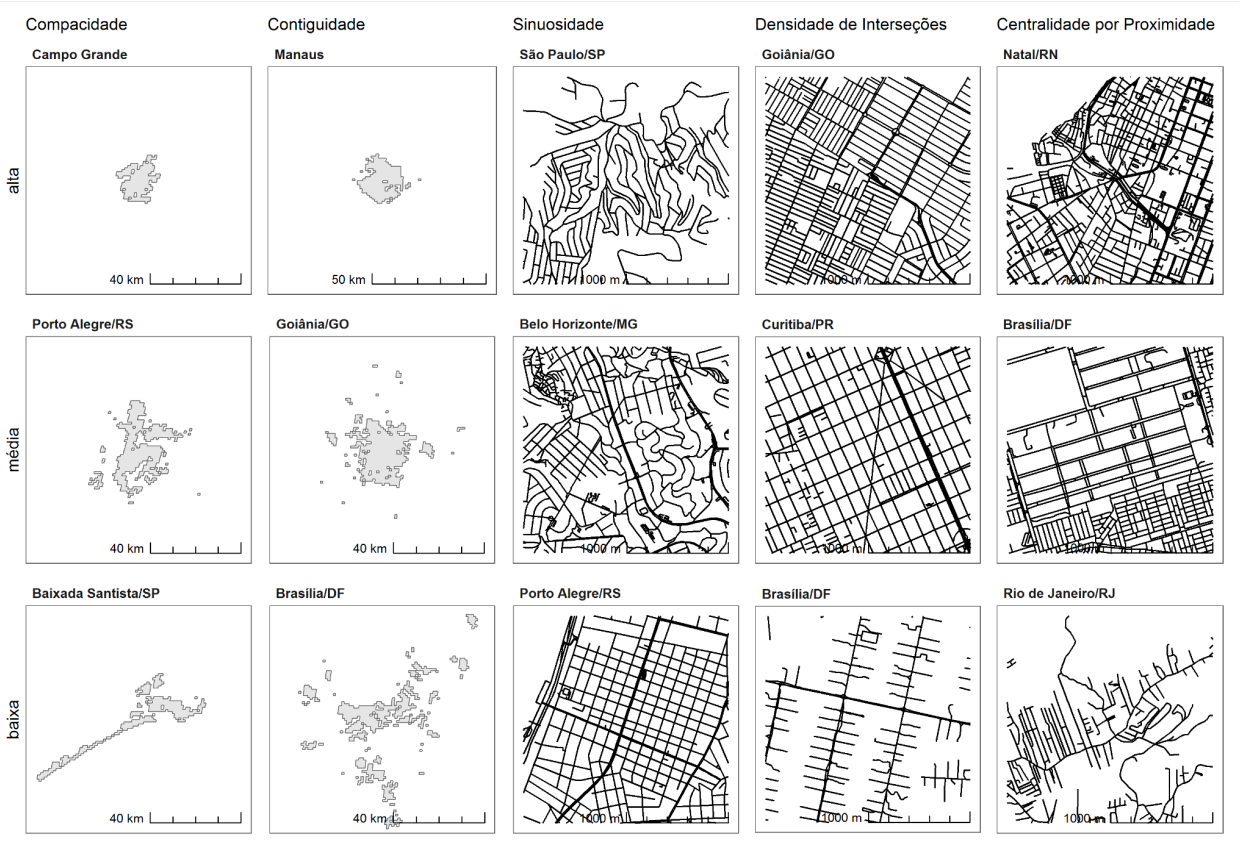

A Tabela 1 sintetiza a influência que estas dimensões de forma urbana teriam sobre comportamentos de viagem das pessoas e que teriam implicações para a sustentabilidade ambiental da mobilidade, conforme a literatura. Tais informações assim sistematizadas serão os principais insumos para a construção de nossos DAGs (cf. Seção 3.6) e, por conseguinte, para a construção dos modelos de regressão que utilizaremos para analisar os efeitos causais da forma urbana sobre o consumo de energia na mobilidade urbana.

Tabela 1: Relação entre dimensões de forma urbana e padrões de viagem.

Dimensão de forma urbana	Característica da viagem	Direção da relação	Referências
Compacidade	Modo de viagem	Cidades mais compactas associadas a maior uso de modos ativos (a pé e bicicleta) e transporte público	(Bento et al., 2005; Ewing et al., 2015; Hamidi & Ewing, 2014)
	Quantidade de quilômetros percorridos por um veículo (QPV)	Cidades mais compactas associadas a menores quantidades médias de quilômetros percorridos por veículo	(S. Lee & Lee, 2020)
Densidade populacional	Modo da viagem	Maior densidade populacional associada a maior uso de modos ativos e transporte público	(Ahlfeldt & Pietrostefani, 2019*; Cervero & Kockelman, 1997; Duranton & Turner, 2018; Ewing & Cervero, 2001*, 2010*; Gainza & Livert, 2013; Guerra & Li, 2021; Marquet & Miralles-Guasch, 2015; Saeidizand et al., 2022; Sinnett & Williams, 2021; Van Acker & Witlox, 2010)
	Quilômetros percorridos por um veículo (QPV)	Maior densidade populacional associada a menor quantidade média de quilômetros percorridos por veículo	(Ahlfeldt & Pietrostefani, 2019*; Brownstone & Golob, 2009; Cervero & Kockelman, 1997; Duranton & Turner, 2018; Ewing et al., 2014; Ewing & Cervero, 2010*; Hong et al., 2014; S. Lee & Lee, 2014, 2020; Marquet & Miralles-Guasch, 2015; McIntosh et al., 2014; S. Song et al., 2016; Stevens, 2017*; Zegras, 2010)
	Posse de automóvel	Maior densidade populacional associada a menor posse de automóveis	(Bento et al., 2005; Van Acker & Witlox, 2010; Zegras, 2010)

Mix de uso do solo	Modo da viagem	Maior mix de uso do solo (diversidade de atividades) associado a maior uso de modos ativos e transporte público	(Cervero, 2002; Cervero & Kockelman, 1997; De Vos et al., 2021; Des Rosiers et al., 2017; Ding et al., 2018; Ewing et al., 2015; Ewing & Cervero, 2010; Hamidi & Ewing, 2014; Sinnett & Williams, 2021; Van Acker & Witlox, 2010)
	Quilômetros percorridos por um veículo (QPV)	Maior mix de uso do solo associado a menor quantidade média de quilômetros percorridos por veículo	(Cervero & Kockelman, 1997; Ewing et al., 2015; Ewing & Cervero, 2001*, 2010*; Zegras, 2010)
	Posse de automóvel	Maior mix de uso do solo associado a menor percentual da população com posse de automóvel	(Bento et al., 2005; Van Acker & Witlox, 2010; Zegras, 2010)
Densidade de interseções da malha viária (intersection density)	Modo da viagem	Maior densidade de ruas e esquinas associada a mais viagens por modos ativos e transporte público	(Ewing & Cervero, 2010*; Sinnett & Williams, 2021)
	Quilômetros percorridos por um veículo (QPV)	Maior densidade de ruas e esquinas associada a menor quantidade média de quilômetros percorridos por veículo	(Ewing et al., 2015; Ewing & Cervero, 2001*, 2010*; Zegras, 2010)
	Posse de automóvel	Maior densidade de ruas esquinas associada a menor percentual da população com posse de automóvel	(Zegras, 2010)

Conectividade da rede viária (centrality / connectivity)	Modo da viagem	Maior conectividade da rede viária associada a mais viagens por modos ativos e transporte público	(Cervero & Kockelman, 1997; Ewing & Cervero, 2001*, 2010*; Sinnett & Williams, 2021)
	Quilômetros percorridos por um veículo (QPV)	Maior conectividade da rede viária associada a menor quantidade média de quilômetros percorridos por veículo	(Cervero & Kockelman, 1997; Ewing et al., 2015; Ewing & Cervero, 2010*; S. Lee & Lee, 2020; Stevens, 2017*)
Sinuosidade das vias	Extensão das viagens	Vias mais sinuosas associadas a viagens com distâncias mais extensas	(Cervero & Kockelman, 1997; Ewing & Cervero, 2001*; Giacomin & Levinson, 2015)

* Estudos de meta análise: Ewing e Cervero (2001) fazem uma meta-análise de mais de 50 artigos, enquanto Ewing e Cervero (2010) cobrem mais de 200 artigos. Stevens (2017) é uma meta-análise de 37 artigos, e Ahlfeldt e Pietrostefani (2019) é uma meta-análise de mais de 40 artigos relacionados ao transporte.

3.5. Análise fatorial de dimensões de forma urbana

Como observado em estudos anteriores, alguns indicadores de forma urbana podem ser correlacionados entre si porque medem dimensões de morfologia urbana interdependentes (Lemoine-Rodríguez et al., 2020; Schwarz, 2010). Por exemplo, cidades espraiadas/menos compactas tendem a ter menor densidade (Lemoine-Rodríguez et al., 2020).

A inclusão de variáveis explicativas altamente correlacionadas entre si em modelos de regressão pode gerar problemas de multicolinearidade, afetando a significância estatística dos coeficientes na regressão. Para lidar com isso, estudos anteriores fazem uma análise de componentes principais (ACP) das métricas de forma urbana (Hamidi & Ewing, 2014; Lemoine-Rodríguez et al., 2020; Schwarz, 2010). O objetivo da ACP é identificar grupos de indicadores muito associados entre si, e agrupá-los em novas variáveis que conseguem sintetizar a variância de cada grupo e minimizar a covariância com os demais grupos.

Neste trabalho, nós fizemos uma análise de componentes principais dos indicadores de forma urbana calculados para as 182 aglomerações urbanas no Brasil. Considerando uma carga

fatorial (*loading factor*) mínima de 0.5, nós identificamos que as dimensões de contiguidade, compacidade e densidade de interseções da malha viária estão muito associadas (ver tabela no apêndice 1). Para as áreas de concentrações urbanas brasileiras, portanto, o único vetor criado foi o dos indicadores de contiguidade, compacidade e de densidade de interseções das vias. Deste modo, nos modelos de regressão da seção seguinte, essas variáveis foram substituídas pelo vetor gerado na análise de componentes principais. Nenhum outro conjunto de variáveis apresentou uma associação significativa, de modo que as variáveis originais foram utilizadas nas regressões.

3.6. Modelo Causal e seleção de variáveis

Nesta seção, elaboramos o modelo causal teórico que associa a forma urbana ao consumo de energia relacionado à mobilidade. Formalizamos as relações entre variáveis por meio de um DAG. Essa estratégia torna explícitas as hipóteses e pressupostos sobre o processo gerador dos dados (Greenland et al., 1999; Pearl, 1995) e auxilia na correta seleção de variáveis de controle em modelos de regressão, de maneira a identificar um efeito causal menos enviesado das variáveis de interesse (Cunningham, 2021; Huntington-Klein, 2021). O diagrama causal permite ainda identificar implicações testáveis acerca da relação mais geral entre as variáveis do modelo, além de facilitar o mapeamento de especificações empíricas alternativas que deveriam levar aos mesmos resultados. Esses recursos permitem testar a validade do modelo teórico e garantir a sua interpretação causal.

O canal pelo qual a forma urbana afeta o consumo de energia no transporte urbano é por meio de sua influência sobre o comportamento de viagem das pessoas, seja em termos de escolhas por modo de transporte ou em termos da média de quilômetros viajados por veículo (Meurs & Haaijer, 2001). Com base na revisão de literatura sintetizada na tabela 1, a Figura 4 introduz uma proposta de DAG que representa as relações casuais mais relevantes de como a forma urbana afeta os padrões de comportamento de viagem e consumo energético. Como não existem dados disponíveis sobre comportamento de viagem em todas áreas urbanas brasileiras, essas variáveis são tratadas como variáveis não observadas.

Figura 4: Grafo acíclico dirigido sobre forma urbana e consumo de energia per capita na mobilidade urbana.

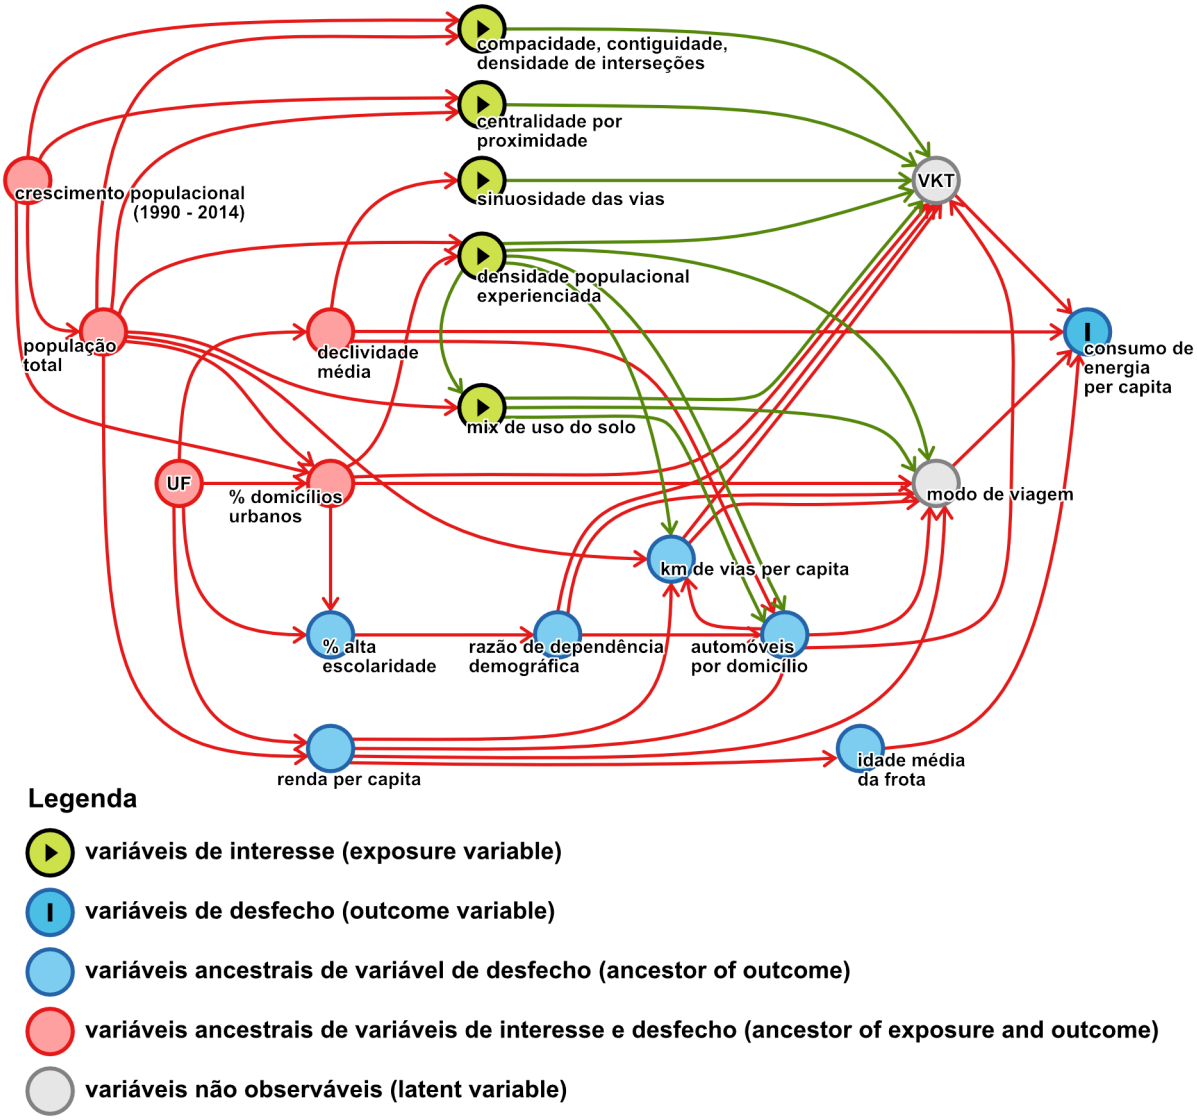

Obs: VKT - Média de quilômetros viajados por veículo.

Além de mostrar que o canal pelo qual as variáveis de forma urbana das cidades podem afetar o consumo de energia na mobilidade é por meio da sua influência sobre padrões de viagem, esse diagrama também mostra os principais determinantes da própria forma urbana. Por exemplo, o DAG torna explícito nosso pressuposto de que localidades com maior população e que tiveram mais rápido crescimento populacional tenderiam a apresentar um tecido urbano menos compacto e mais fragmentado. Cidades com rápido crescimento populacional também tenderiam a ter um

crescimento da malha viária de forma mais orgânica e menos ordenada, com menor closeness centrality. Já a sinuosidade do sistema viário é afetada em grande medida pela topografia da cidade, que por sua vez varia muito entre os diferentes estados do país devido a sua formação geomorfológica. A própria condição do relevo da cidade também afeta diretamente a quantidade de energia utilizada em viagens em função da declividade das ruas. Além disso, cidades tendem a ser mais densas quanto maior a sua população e maior a proporção de domicílios em áreas urbanas, enquanto o tamanho e densidade populacional também influenciam o nível de mix de uso do solo.

Cabe destacar ainda outras variáveis que podem modificar, direta ou indiretamente, a relação entre forma urbana e mobilidade. Por exemplo, cidades com maior população tendem a ter maior renda familiar per capita devido a economias de aglomeração e economias de escala, com melhor aproveitamento da infraestrutura instalada e maior produtividade econômica (Bettencourt & West, 2010; Kühnert et al., 2006; Ribeiro et al., 2021). Por sua vez, cidades mais ricas tendem a ter maior proporção de domicílios com automóvel, uma frota de veículos em média mais nova e maior oferta de malha viária por habitante.

Ainda, deve-se levar em conta que a trajetória de desenvolvimento de uma cidade também é influenciada por fatores culturais e históricos (aí incluída sua legislação urbanística e edilícia), sua velocidade da urbanização, o nível de riqueza e produtividade da sua economia e de suas características topográficas e geográficas. No contexto latino-americano, as características culturais e de legislação seriam relativamente mais parecidas entre cidades brasileiras devido ao histórico de colonização portuguesa (Duque et al., 2019). No entanto, as diferentes trajetórias de desenvolvimento entre os estados e grandes regiões do país explicam em boa parte a variação espacial da renda e do nível de escolaridade da população, assim como o padrão espacial da topografia do país. Assim, o estado no qual cada cidade se localiza é inserido no DAG como variável que captaria indiretamente todas as comunalidades aos municípios do mesmo estado, incluindo eventualmente legislações estaduais, e características culturais, geográficas e históricas compartilhadas de sua trajetória de desenvolvimento.

A construção do DAG, além de tornar explícitos os pressupostos da análise, permite avaliar todos os possíveis caminhos causais e identificar aquelas variáveis de controle que são imprescindíveis para a estimação e aquelas que poderiam acarretar vieses, se incluídas (*bad controls* ou *colliders* - cf. Huntington-Klein, 2021; Montgomery et al., 2018). Por exemplo, a variável ‘número de automóveis por domicílio’ é collider das variáveis de forma urbana densidade

experienciada e mix de uso do solo, além de ser um mediador da relação entre essas variáveis e o consumo de energia per capita. e portanto deve ser excluída do modelo de regressão.

Neste trabalho, nós construímos o DAG com auxílio da ferramenta online "DAGitty" <<http://dagitty.net/>>. O DAG foi então importado e analisado no R utilizando-se o pacote "dagitty" (Textor et al., 2016). A tabela 3, a seguir, apresenta o conjunto de variáveis analisadas no DAG para construção dos modelos de regressão:

Tabela 3. Variáveis incluídas no modelo de regressão.

Variável e descrição	Fonte (ano)	Dimensão
Consumo médio de energia per capita Energia total (em Toneladas de Petróleo Equivalente) do consumo de combustível (gasolina e etanol hidratado) per capita	Agência Nacional de Petróleo (2010)	Ambiental
Mix de uso do solo Índice global de dissimilaridade para área de concentração urbana considerando 7 diferentes categorias de uso do solo	CNEFE / IBGE (2010)	Forma Urbana
Densidade populacional experienciada Média da densidade populacional experienciada localmente num raio de 2 km	GHSL (2015)	Forma Urbana
Compacidade Soma do inverso das distâncias euclidianas entre as células que compõem a área urbana, normalizada pela compacidade máxima possível para uma cidade de mesmo porte.	GHSL (2014)	Forma Urbana
Contiguidade Proporção da totalidade do território da área de concentração urbana preenchido pela sua maior área urbanizada consolidada contígua	GHSL (2014)	Forma urbana
Centralidade por proximidade normalizada Inverso da distância média entre os nós da rede viária da área de concentração urbana, normalizada pela extensão da rede viária	OpenStreetmap (2020)	Forma Urbana (configuração da rede viária)
Densidade de intersecções Total de cruzamentos da malha viária dividido pela área urbanizada total da área de concentração urbana	OpenStreeMap (2020)	Forma Urbana (configuração da rede viária)
Fator de sinuosidade das vias Média das razões entre comprimento de cada segmento de via e a distância euclidiana entre suas extremidades.	OpenStreeMap (2020)	Forma Urbana (configuração da rede viária)
Idade média da frota de veículos Idade média dos veículos privados (automóveis e motocicletas) considerando o ano base de 2020	Registro Nacional de Veículos Automotores / DENATRAN 2020	Econômica

... continuação da tabela 3

Variável e descrição	Fonte (ano)	Dimensão
Renda domiciliar per capita média Média da renda domiciliar per capita de indivíduos residentes em domicílios em situação urbana	Censo (2010)	Socio-econômica
Proporção de indivíduos com alta escolaridade Proporção de indivíduos residentes em domicílios em situação urbana com ensino superior completo	Censo (2010)	Socio-econômica
Proporção de domicílios em áreas urbana	Censo (2010)	Socio-econômica
População total População total residente em cada área de concentração urbana	IBGE (2010)	Demográfica
Crescimento populacional Taxa geométrica de crescimento populacional entre 1990 e 2015	GHSL (1990 e 2015)	Demográfica
Razão de dependência demográfica Razão entre população de 0-14 e 65+ anos e a população entre 15-64 anos de idade	Censo (2010)	Demográfica
Declividade média da topografia Nível médio de declividade do terreno da área de concentração urbana	NASA (2015)	Geográfica
Estado da federação Variável binária (dummy) indicando em qual Unidade da Federação está localizada a área de concentração urbana	IBGE (2010)	Geográfica

3.7. Estimação

Como mencionado na seção 3.6, nós incluímos todas as variáveis de controle mapeadas como adequadas pela análise do grafo causal. Testamos ainda a significância estatística de interações das variáveis de forma urbana entre si e com a variável de tamanho populacional. A única interação que apresentou significância, e portanto foi incluída na regressão, foi a interação entre tamanho populacional e o fator de compacidade-contiguidade-densidade de interseções.

O principal modelo de regressão apresentado neste estudo é o modelo canônico, que inclui o maior número de controles (excluindo aqueles que poderiam causar vieses) para estimar simultaneamente o efeito de todas variáveis de forma urbana sobre o consumo de energia na mobilidade. Além disso, por meio da análise sistemática do gráfico causal acima, é possível apontar

diferentes especificações empíricas alternativas que seriam igualmente capazes de levar à estimação correta dos efeitos de cada variável de forma urbana separadamente. Isto é, nós poderíamos estimar outras regressões com diferentes conjuntos de controles que, em princípio, sob a hipótese da correta especificação do modelo, deveriam levar a resultados estatisticamente idênticos ao modelo canônico. Os resultados principais do modelo principal são apresentados na seção de resultados 4.3. Os resultados dessas especificações alternativas são apresentados no anexo 1. Os coeficientes encontrados são estatisticamente iguais àqueles estimados no modelo canônico. Isso indica boa robustez do modelo causal proposto e dos resultados, uma vez que encontramos resultados iguais mesmo quando utilizamos regressões com seleções de variáveis diferentes.

A estimação foi feita por Mínimos Quadrados Ordinários com dados em corte transversal, especificação log-log e com erros clusterizados por macrorregiões do Brasil. O modelo segue a especificação da equação abaixo:

$$logY_{iUF} = \alpha + \eta FCID_i + \mu FCID_i * Pop_i + \varphi SinuVias_i + \delta DensPop_i + \beta UsoSolo_i + \theta Centpprox_i + \gamma X_i + D_{UF} + \varepsilon_{UF} \quad (14)$$

onde *logY* é o log do consumo de energia per capita para a área urbana consolidada *i*, na unidade da federação *UF*, explicado pelo: coeficiente de intercepto, $\boldsymbol{\alpha}$; *FCID*, um vetor resultante do fator que contém a densidade de intersecções de vias e os graus de compacidade e contiguidade da mancha urbana; *FCID*Pop*, que é a interação entre o fator mencionado com a população total; *SinuVias* é o grau de sinuosidade das vias; *DensPop* é a densidade populacional experienciada; *UsoSolo* é o índice de mix de uso do solo; e *Centpprox* é a centralidade por proximidade da malha viária. Todas essas variáveis foram utilizadas em logaritmo natural, e portanto, os seus coeficientes representam elasticidades[i]. Além das variáveis de forma urbana, há o log de um vetor *X* de variáveis de controle em *i*, composto pelas variáveis indicadas na Tabela 3, acima. Por fim, *D* é um vetor de dummies do estado da federação, e $\boldsymbol{\varepsilon}$ representa o erro robusto, clusterizado a nível de região.

A tabela 4 apresenta a estatística descritiva das variáveis utilizadas nos modelos de regressão.

[i] As variáveis X Y Z apresentavam alguns valores negativos. Nesses casos, essas variáveis foram transformadas utilizando-se o arco seno hiperbólico, que se aproxima do logaritmo natural (Bellemare & Wichman, 2020).

Tabela 4. Estatísticas descritivas das variáveis utilizadas nos modelos de regressão.

Variável	Mínimo	Média	Máximo	Desvio padrão
Energia per capita x 10000	0.2	2.3	5.2	0.9
Fator de contiguidade, compacidade e intersecção de vias	-3.6	0	1.6	1
Sinuosidade das vias	1	1.1	1.3	0
Densidade populacional experienciada 2km	1133.4	4003.8	13482.9	1864.3
Mix de uso do Solo	0.6	0.7	0.9	0
Centralidade por proximidade	0.4	0.7	0.8	0.1
Idade Média da frota de veículos	9.5	11.8	14.8	1
Declividade média da topografia	1.6	4.7	17.4	2.6
População total em 2010	100014	626570.2	19629394	1802457.9
Percentual de domicílios urbanos (%)	46.5	92	99.9	7.8
Percentual de população com ensino superior (%)	2.4	8	14.7	2.5
Razão de dependência demográfica	0.3	0.4	0.7	0
Taxa média de crescimento populacional anual entre 1990 e 2015 (%)	-1.6	2.9	11.8	1.5
Renda média per capita	316.5	832.1	1443.2	213

4. RESULTADOS

4.1. Recente histórico da urbanização brasileira

Antes de analisar os resultados sobre forma urbana e mobilidade sustentável das áreas de concentração urbana, nós apresentamos nesta subseção uma breve análise do histórico do crescimento populacional dos municípios brasileiros. Esta análise é importante uma vez que a forma urbana das cidades de hoje é resultado de um acumulado histórico dos seus processos de planejamento urbano e crescimento populacional (van de Coevering & Schwanen, 2006).

Assim como diversos países da América Latina, se observou no Brasil ao longo de boa parte do século 20 grandes fluxos migratórios das zonas rurais para as médias e grandes cidades, o

que contribuiu para o rápido processo de urbanização do país (Rodríguez-Vignoli & Rowe, 2018). Nos últimos 50 anos, a proporção da população urbana no Brasil subiu de 56% em 1970 para 86% em 2020 (Figura 5). Apesar do rápido crescimento das cidades brasileiras durante boa parte do século 20, todas as regiões do país vêm convergindo para um mais baixo ritmo de crescimento populacional pelo menos desde a década de 1970 (Figura 6).

Figura 5: População conforme situação de domicílio urbano ou rural. Brasil, 1970 - 2020.

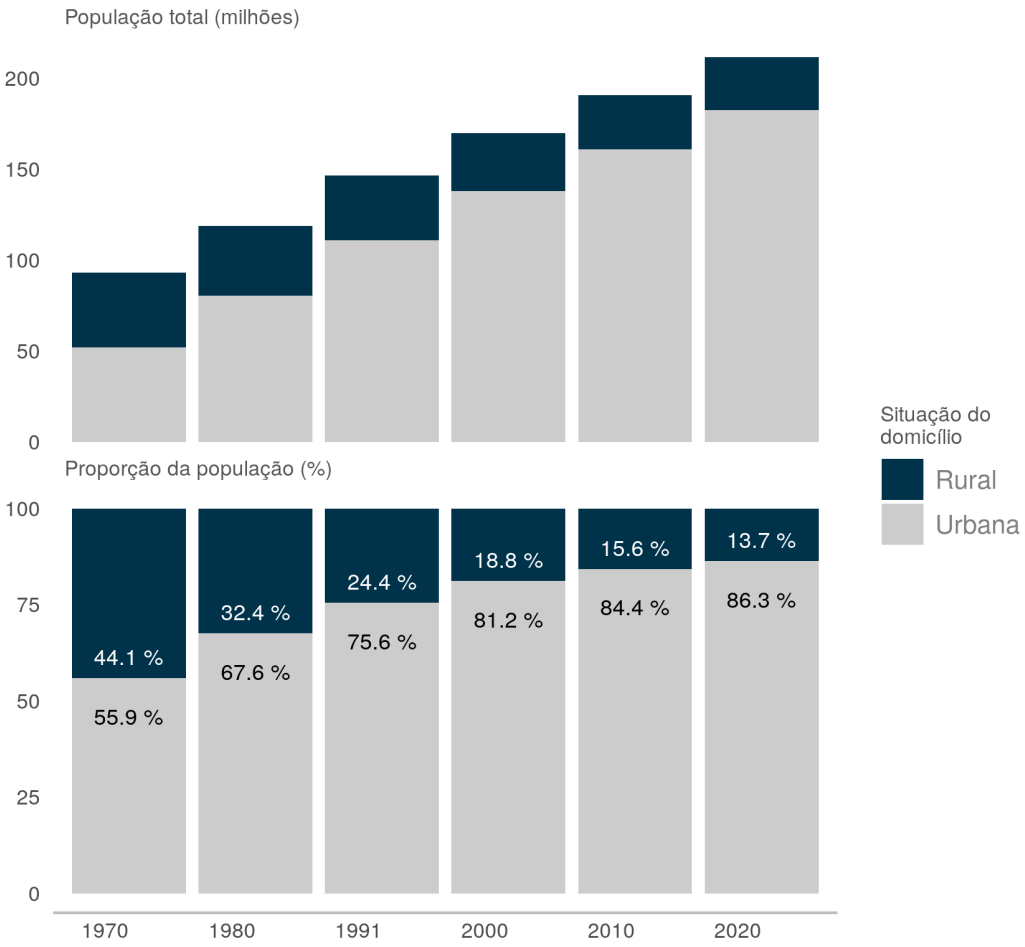

Fonte: Censos IBGE (1970, 1980, 1991, 2010) e PNAD (2020)

Figura 6: Taxa geométrica de crescimento populacional do Brasil e grandes regiões, 1970 - 2020.

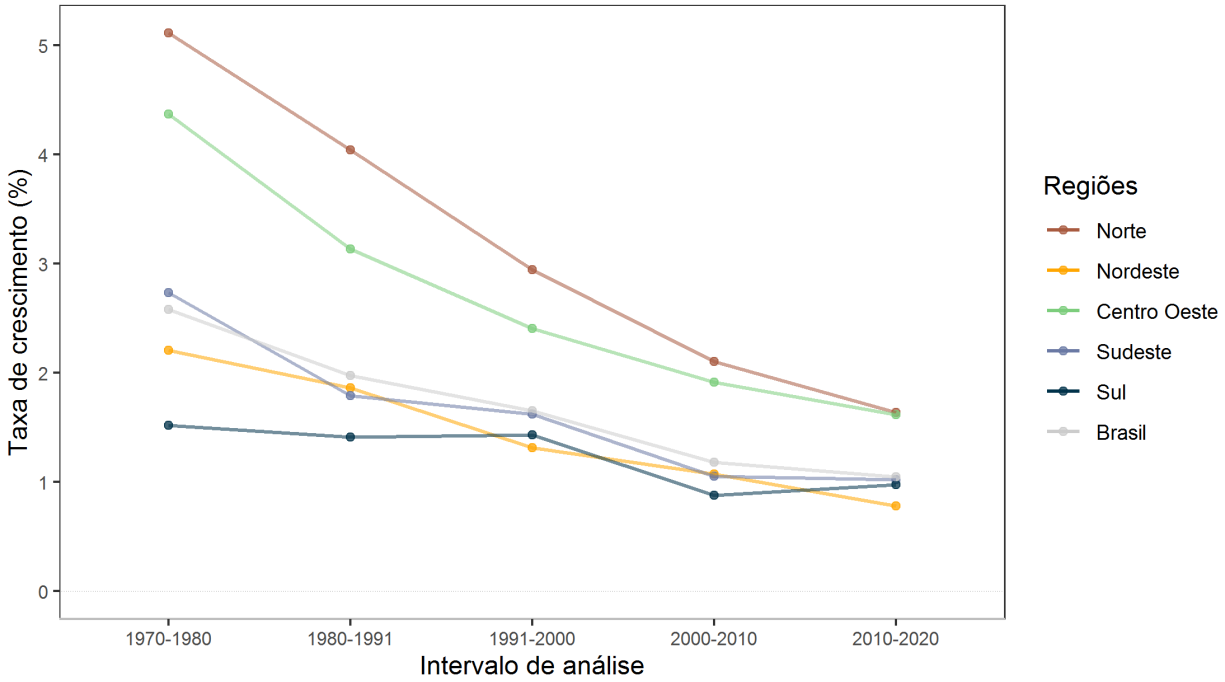

Fonte: Censos IBGE (1970, 1980, 1991, 2010) e projeção populacional (2020).
Faixas populacionais definidas conforme Áreas Mínimas Comparáveis (AMC), desde 1970.

Destaca-se que entre os anos 70 e 90 se observou uma grande diferença no ritmo de crescimento das pequenas, médias e grandes cidades (Figura 7). Até os anos 90, boa parte dos municípios pequenos tiveram decréscimo populacional puxado em grande parte pela migração da sua população para médias e grandes cidades, que apresentavam altas taxas de crescimento. A partir dos anos 90, várias cidades médias (entre 100 e 500 mil habitantes) passaram a ter crescimento mais acelerado do que os grandes centros urbanos consolidados do país. Desde os anos 80, no entanto, é notável como houve no Brasil uma convergência generalizada para baixas taxas de crescimento populacional nas cidades — em todas as faixas de tamanho.

Figura 7: **Taxa geométrica de crescimento populacional dos municípios segundo faixa populacional. Brasil, 1970 - 2020**

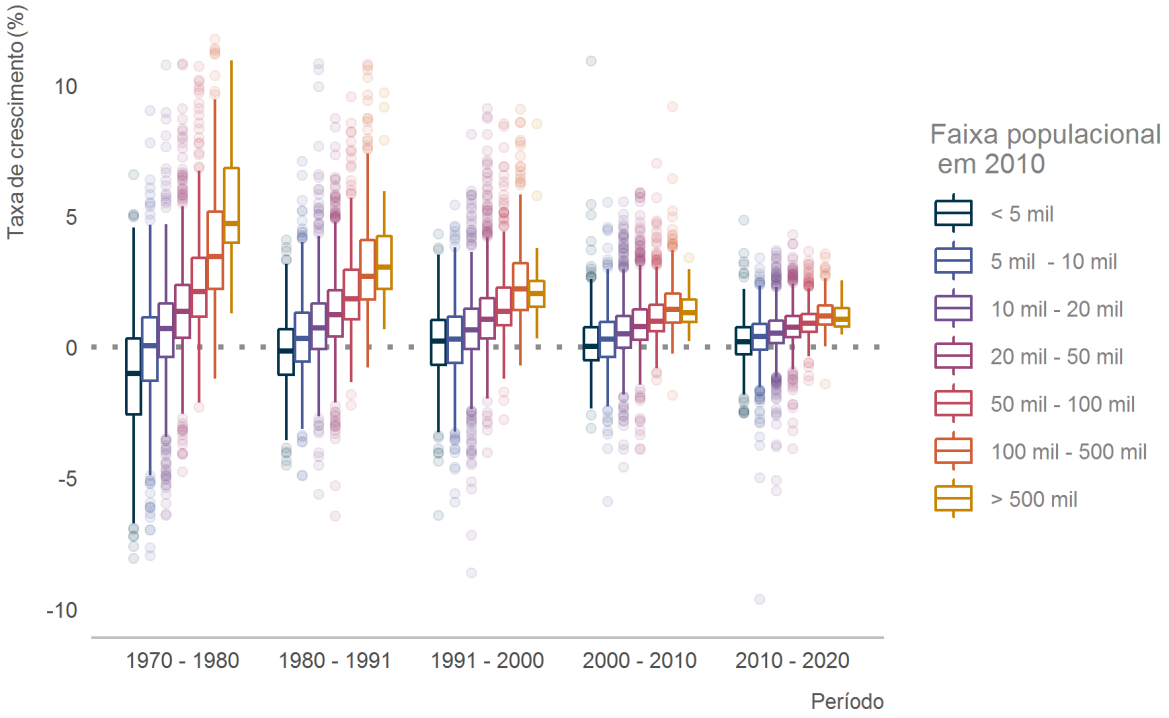

Fonte: Censos IBGE (1970, 1980, 1991, 2010) e projeção populacional (2020).
Faixas populacionais definidas conforme Áreas Mínimas Comparáveis (AMC) entre 1970-2010

Obs. Classificação da faixa populacional dos municípios feita com base na população estimada no ano de 2010.

Essa convergência para baixas taxas de crescimento populacional também tem sido observada nas maiores regiões metropolitanas do Brasil (Figura 8). Apesar dessa convergência, no entanto, nota-se que os municípios das periferias metropolitanas sempre tiveram ritmo de crescimento populacional mais acelerado do que as sedes metropolitanas. As exceções a isso ocorreram em algumas regiões metropolitanas como Brasília, Fortaleza e Goiânia na década de 1970, e na região metropolitana de Manaus. Esse ritmo mais rápido de crescimento populacional das periferias metropolitanas provavelmente contribuiu historicamente para um padrão de ocupação urbana menos compacto e mais espraiado. A seguir, nós analisamos como os últimos 30 anos de crescimento populacional das áreas urbanas brasileiras têm se organizado espacialmente.

Figura 8. Taxa geométrica de crescimento populacional dos municípios das 12 maiores regiões metropolitanas. Brasil, 1970-2020.

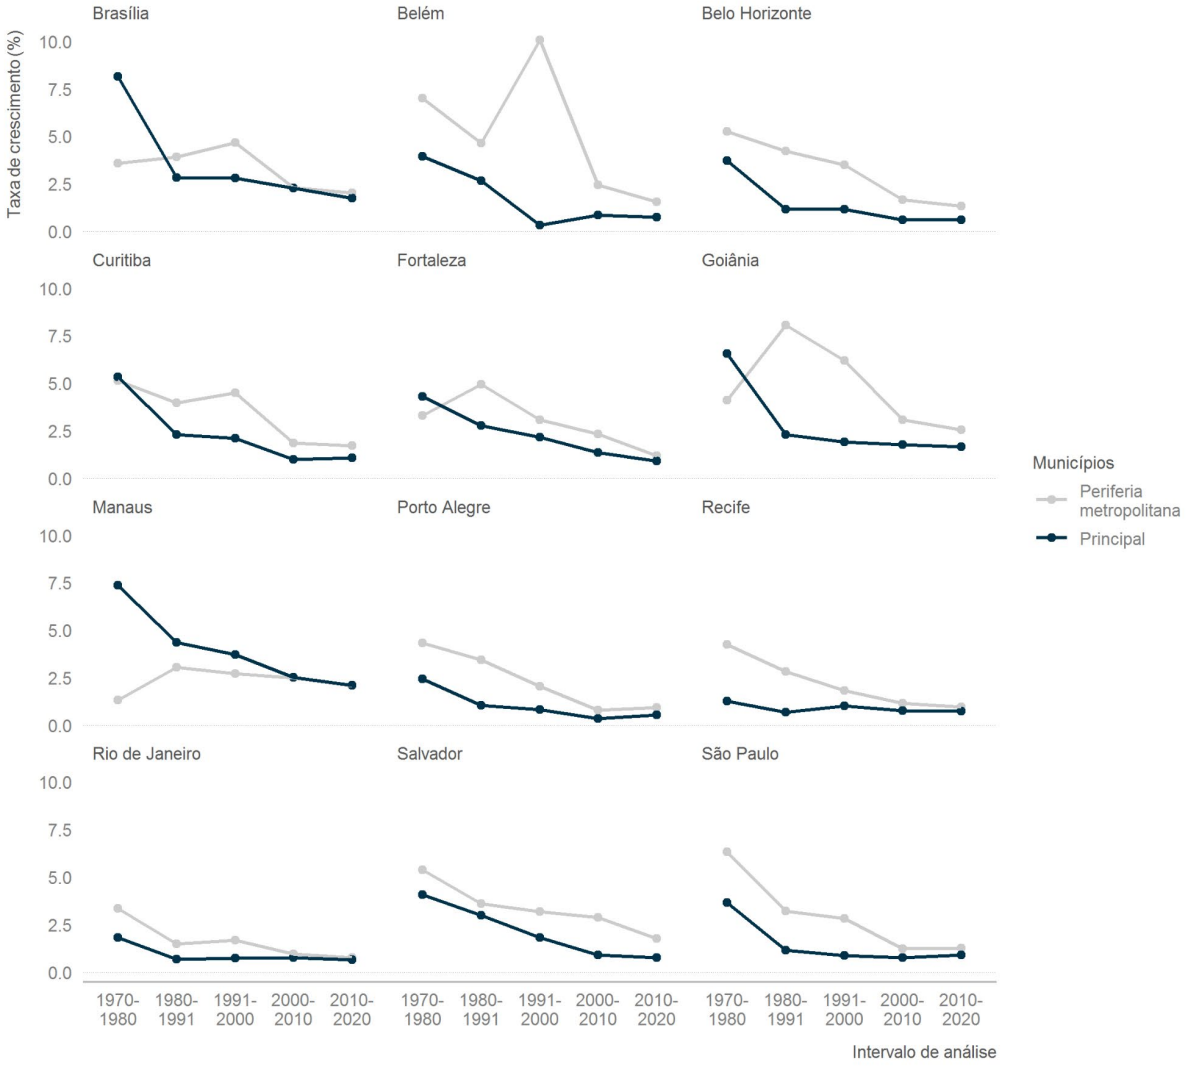

Fonte: Censos IBGE (1970, 1980, 1991, 2010) e projeção populacional (2020).
Faixas populacionais definidas conforme Áreas Mínimas Comparáveis (AMC), desde 1970.

4.2. A forma urbana das cidades brasileiras

Entre 1990 e 2014, cidades médias e grandes apresentaram diferenças significativas no seu padrão de crescimento espacial (Figura 9). Nesse período, cidades grandes cresceram principalmente pelo adensamento de suas áreas urbanizadas, o que pode ser explicado em parte por sua grande área consolidada já existente em 1990. Cidades grandes também apresentam taxas de crescimento por preenchimento maiores que por *leapfrog*, indicando um padrão de crescimento com maior

aproveitamento da infraestrutura existente e diminuição das distâncias a serem percorridas. Em contraste, nas cidades médias se observa taxas de crescimento similares por adensamento e extensão, indicando os dois principais vetores de crescimento dessas cidades. Além disso, essas cidades apresentam taxas de crescimento por leapfrog significativamente mais altas, indicando um padrão de crescimento com maior fragmentação da área urbanizada. Essa fragmentação tende a ser menos sustentável, pois ela gera maiores custos de urbanização e manutenção da infraestrutura urbana, pois essa infraestrutura precisa ser estendida por distâncias maiores.

Figura 9. Taxas de crescimento da área urbanizada segundo tipo de expansão urbana das aglomerações urbanas brasileiras, 1990-2014.

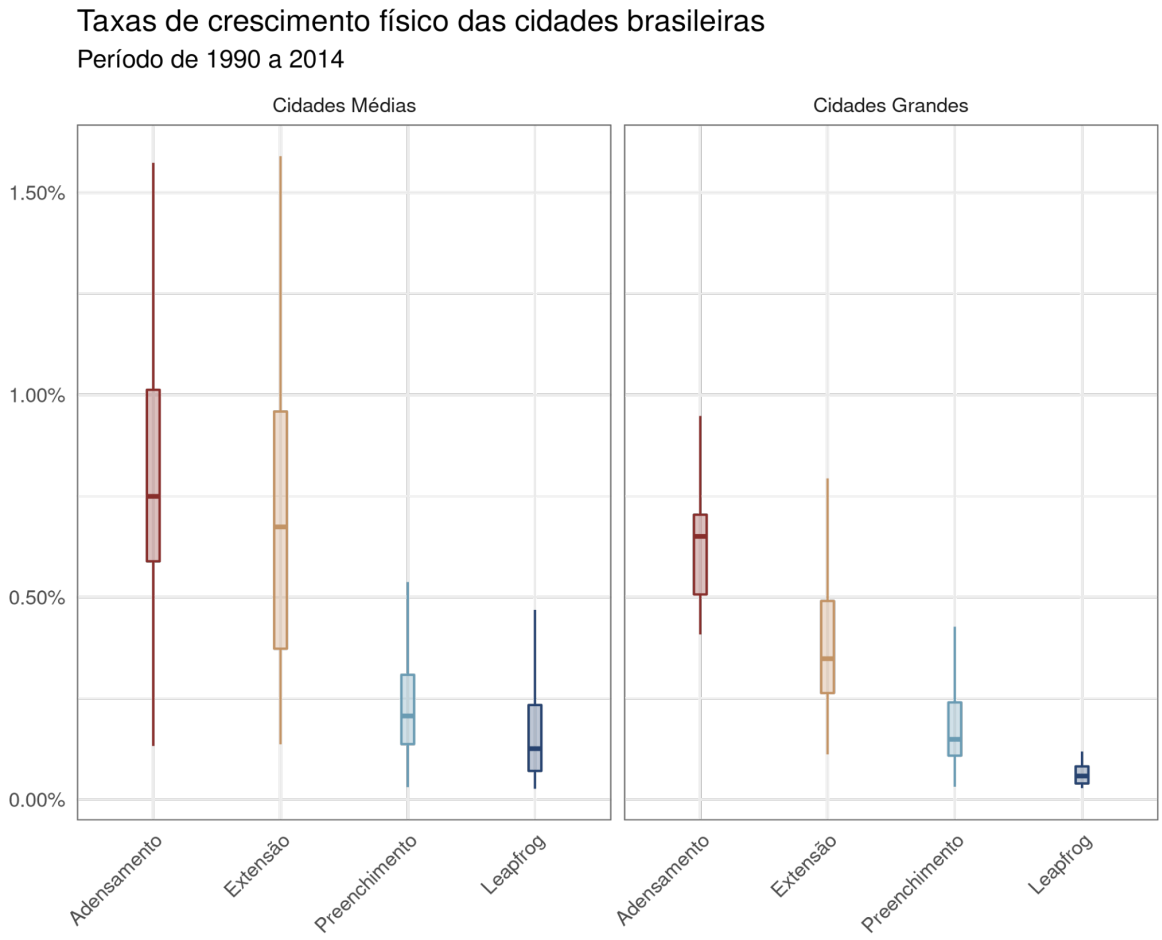

Obs. Cidades médias: população entre 100 mil e 1 milhão de habitantes; cidades grandes: população acima de 1 milhão de habitantes.

A Figura 10 apresenta a comparação entre as taxas de crescimento populacional e da área construída das 182 aglomerações urbanas brasileiras, no período de 1990 a 2014/2015[j]. A grande maioria das áreas urbanas brasileiras apresentou taxas de crescimento populacional maiores que as taxas de crescimento físico, em cidades de todos os tamanhos. Esse padrão indica uma tendência geral de adensamento das cidades brasileiras, concentrando um número crescente de pessoas em um espaço físico que não se espalha tão rapidamente. Essa tendência é mais predominante entre as cidades grandes, das quais 32% possuem crescimento populacional pelo menos duas vezes mais rápido que o crescimento da área construída, em comparação com 22% das cidades médias. Porém, algumas cidades médias possuem valores mais extremos. Em três cidades médias a população cresceu mais que cinco vezes mais rápido que a área construída: Aracaju / SE, Tramandaí – Osório / RS, e Boa Vista / RO (cuja diferença foi de 9 vezes, a maior de todas), indicando forte adensamento e preenchimento de espaços vazios intra-urbanos.

No outro sentido, apenas 34 cidades tiveram a taxa de crescimento da sua mancha urbana maior do que a taxa de crescimento da população, sendo que em 9 delas a diferença entre as taxas foi superior a 25%. Todas as 34 cidades são de porte médio, sendo que Ilhéus / BA e Lages / SC foram os casos mais extremos. Ilhéus é um caso emblemático onde houve decréscimo da população, a uma taxa de -1,6% ao ano no período. Já Lages teve crescimento populacional no período, porém a área construída cresceu duas vezes mais rapidamente. A única cidade com mais de um milhão de habitantes em que a mancha urbana cresceu num ritmo próximo ao crescimento demográfico foi Porto Alegre/RS, cuja taxa de crescimento populacional foi apenas 2,5% superior à taxa de crescimento físico.

[j] Essa relação entre a taxa de crescimento populacional e a taxa de crescimento da área construída das cidades é um dos indicadores oficiais sobre sustentabilidade urbana utilizados pelas Nações Unidas para monitorar os Objetivos de Desenvolvimento Sustentável (ODS) (Pereira et al., 2019).

Figura 10. Comparação entre taxas de crescimento populacional e crescimento da área construída das aglomerações urbanas brasileiras, 1990 – 2014: a) taxas de crescimento geométrico de população e de área construída; b) razão entre as taxas de crescimento populacional e de área construída.

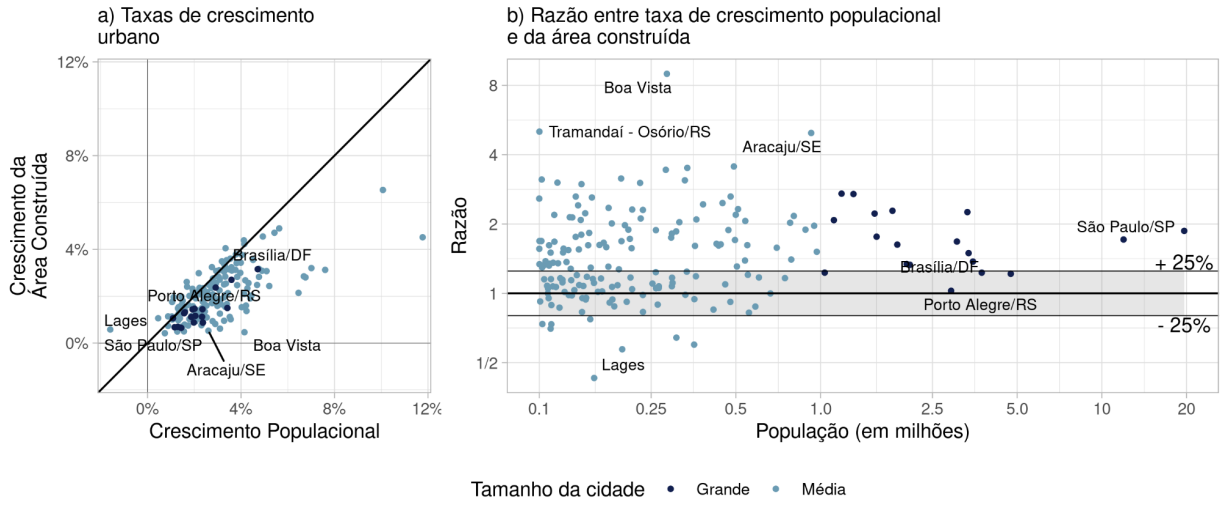

Obs. Cidades médias: população entre 100 mil e 1 milhão de habitantes; cidades grandes: população acima de 1 milhão de habitantes.

Também houve mudanças nos padrões de compacidade, fragmentação e densidade das cidades brasileiras entre 1990 e 2014 (Figura 11). O painel A da figura 11 indica que a compacidade das cidades médias teve uma leve diminuição no período, enquanto as cidades grandes tiveram um leve aumento na compacidade, o que fica mais evidente pelo deslocamento da linha vertical indicativa da compacidade mediana de cada grupo de cidades. Isso indica que cidades grandes têm crescido de forma a preencher espaços deixados vazios durante o período anterior de expansão, enquanto as cidades médias têm ido na direção contrária, crescendo em formas mais irregulares e com formação de vazios urbanos.

A variação do indicador de contiguidade (Figura 11B) também indica padrões diferentes entre cidades médias e grandes. As cidades maiores tiveram um aumento no índice de contiguidade entre 1990 e 2000, seguido por uma diminuição do indicador no período seguinte. Isso indica que vários núcleos urbanos dispersos criados no período anterior ao estudo foram incorporados à mancha urbana principal durante a década de 1990. Porém, esse processo foi revertido no período após o ano 2000, indicando a criação de uma nova série de núcleos urbanos fragmentados. Já as

cidades médias, em geral, não passaram por esse aumento de contiguidade durante a década de 1990, mas passaram pelo mesmo processo de fragmentação no período seguinte. O fato dos indicadores de compacidade e fragmentação terem apresentado apenas pequenas variações no período de 24 anos reflete a longa escala temporal em que mudanças nos padrões de ocupação do solo podem ser observadas. Mesmo assim, alguns padrões são visíveis, como a tendência geral ao aumento da fragmentação das áreas urbanas e diminuição da compacidade (ou aumento do espraiamento) das cidades médias. Ambas as tendências apontam para formas urbanas menos sustentáveis.

Entre 1990 e 2014, as cidades brasileiras ficaram ligeiramente menos compactas (Figura 11A), mais fragmentadas (Figura 11B), mas também mais densas (Figura 11C). Essas tendências foram encontradas tanto para cidades médias, entre 100 mil e 1 milhão de habitantes, quanto para cidades grandes, acima de 1 milhão de habitantes. Embora pareça contraditório, uma possível explicação para isso seria que o aumento de densidade observado no período teria sido maior em regiões afastadas da área urbana central consolidada, por exemplo pelo surgimento de novas centralidades urbanas (Nadalin et al., 2018). Isso seria esperado uma vez que um aumento de densidade urbana tende a aumentar a compacidade e contiguidade das cidades quando ocorre em áreas consolidadas, mas também pode contribuir para fragmentação e espraiamento quando ocorre em áreas mais afastadas.

Em síntese, a forma de expansão das médias e grandes cidades brasileiras nos últimos anos segue uma tímida tendência observada na América Latina de redução do espraiamento urbano (Duque et al., 2019), e uma tendência global mais ampla de convergência para formas mais compactas e fragmentadas (Lemoine-Rodríguez et al., 2020).

Figura 11. Variação dos índices de compacidade (A), contiguidade (B) e densidade experienciada (C) das cidades brasileiras entre 1990 e 2014.

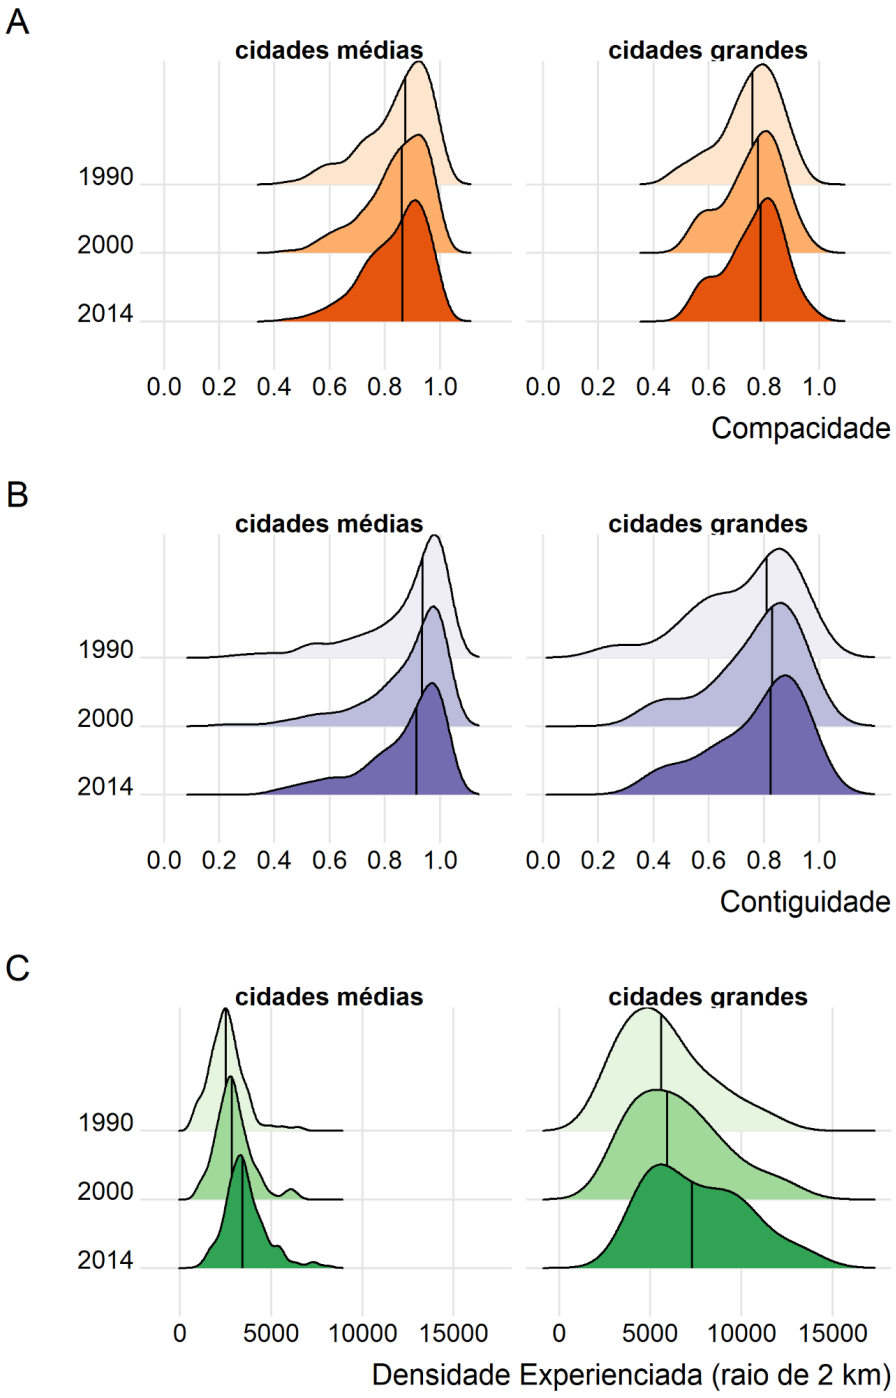

Obs. Linha vertical indica valor mediano de cada indicador. Cidades médias: população entre 100 mil e 1 milhão de habitantes; cidades grandes: população acima de 1 milhão de habitantes.

4.3. Análise multivariada: relação entre forma urbana e consumo de combustível

Nesta seção nós apresentamos apenas os resultados da regressão para as variáveis de forma urbana no modelo canônico. Os resultados completos da regressão incluindo os coeficientes das variáveis de controle estão disponíveis no apêndice 2, mas cabe a nota de cautela de que os coeficientes das covariadas não devem ser interpretados como efeito causal (Keele et al., 2020). No apêndice 2 nós apresentamos também resultados dos modelos com especificações alternativas, além de diagnósticos adicionais, derivados das implicações apontadas pelos DAGs, garantindo a interpretação causal de nossos resultados.

A figura 12 apresenta as estimativas da regressão para os efeitos das variáveis de forma urbana sobre consumo energético na mobilidade. Os principais resultados são:

- Um aumento de 10% no mix de uso do solo leva a uma queda de 7,2% no consumo de energia per capita no transporte motorizado.
- Para cada 10% a mais de densidade populacional, o consumo de energia per capita cai em 1,3%.
- Os efeitos da sinuosidade e conectividade da malha viária não foram estatisticamente significantes.
- Um aumento de 10% no fator compacidade / contiguidade / densidade de intersecções leva a uma redução de 5,8% no consumo de energia do transporte motorizado. No entanto, a magnitude desse efeito se torna cada vez menor quanto maior o tamanho da cidade, até um ponto em que a direção do efeito se inverte. A partir de um porte populacional de aproximadamente 120 mil habitantes, um aumento de 10% de compacidade leva a um aumento de consumo energético de 0,5%.

Esses resultados vão ao encontro da literatura internacional, e confirmam que cidades mais densas com maior mix de uso do solo promovem sistemas de mobilidade urbana mais sustentáveis com menor consumo de energia no transporte motorizado. No entanto, nossos resultados também mostram que o efeito do fator compacidade/contiguidade/densidade do sistema viário sobre consumo de energia é influenciado pelo tamanho populacional da cidade. Isso sugere que maior compacidade/contiguidade e densidade de sistema viário tendem a gerar deseconomias de aglomeração, por exemplo via maiores congestionamentos, em aglomerações urbanas de maior

porte populacional.

Figura 12. Efeitos de diferentes dimensões de forma urbana sobre o consumo de energia per capita no transporte individual motorizado. Áreas de Concentração Urbanas brasileiras, 2010.

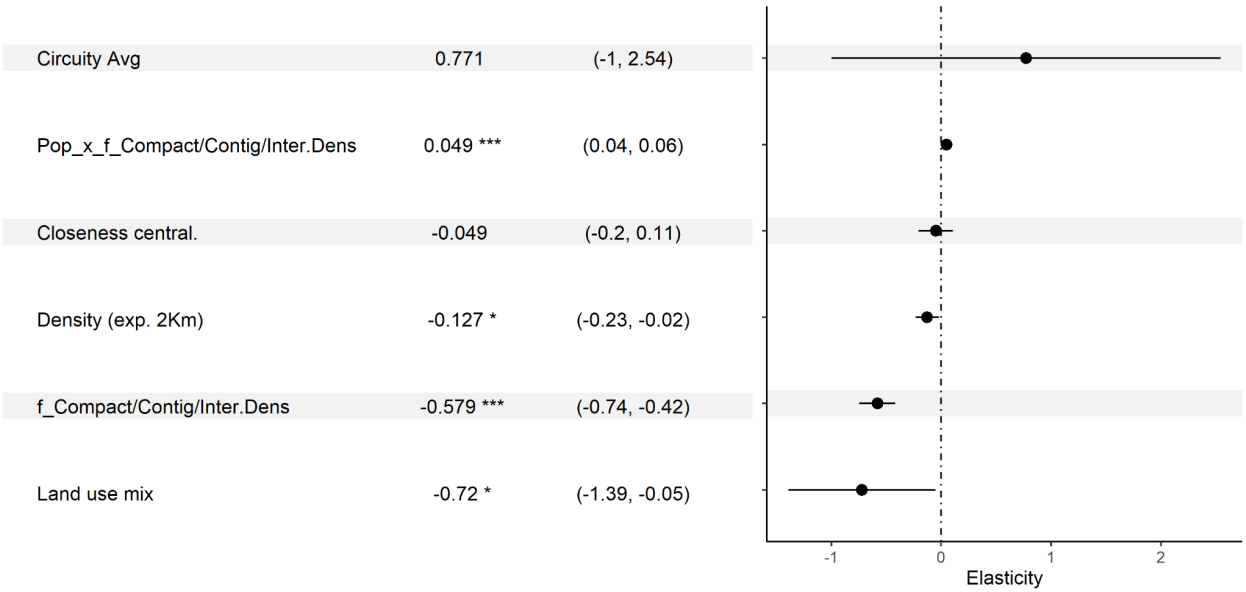

Obs.: Significância dos coeficientes ***: 0.01, **: 0.05, *: 0.1 Intervalos de confiança apresentados entre parênteses ().

5. CONSIDERAÇÕES FINAIS

Este estudo apresentou uma análise de como a configuração espacial das cidades brasileiras mudou entre 1990 e 2015, e analisou a relação entre forma urbana e consumo de energia per capita no transporte individual motorizado considerando todas as 182 aglomerações urbanas do país. Para isso, nós propomos um Grafo Acíclico Dirigido (DAG) para mapear a relação causal entre variáveis de forma urbana e consumo de energia na mobilidade, e utilizamos uma série de modelos de regressão para captar o efeito de diversas características de forma urbana sobre o consumo de energia no transporte individual motorizado.

Os resultados apontam que, entre 1990 e 2015, as grandes cidades brasileiras ficaram mais densas, ligeiramente mais compactas e menos fragmentadas. As cidades médias, por outro lado, apresentaram uma tendência preocupante. Embora elas também tenham se tornado mais densas

nesse mesmo período, as cidades médias ficaram mais fragmentadas e mais espraiadas entre 1990 e 2015. Esse resultado ilustra como um aumento de densidade pode ter diferentes efeitos sobre a forma urbana a depender do local onde ocorre. Um aumento de densidade tende a aumentar a compacidade e contiguidade das cidades quando ocorre em áreas consolidadas, mas também pode contribuir para fragmentação e espraiamento quando ocorre em áreas mais afastadas. Esse resultado é importante porque ilustra como a discussão sobre o papel da densidade na urbanização sustentável é mais complexo do que comumente retratado na literatura (Næss et al., 2020).

Ainda, os resultados da regressão mostram que maior mix de uso do solo e maiores densidades contribuem para um menor consumo energético na mobilidade urbana, o que provavelmente se traduz também em menores níveis de emissões. Isso vai ao encontro dos resultados da literatura internacional, que sugere que áreas urbanas com essas características criam ambientes mais propícios para que pessoas consigam fazer escolhas mais sustentáveis de mobilidade, por exemplo realizando viagens mais curtas e usando modos de transporte público e ativos. Nossos resultados mostram ainda que o efeito da compacidade e contiguidade do tecido urbano sobre consumo de energia é influenciado pelo porte populacional da cidade. Nós encontramos que, para cidades acima de 120 mil habitantes, cidades mais compactas/contíguas tendem a ter um ligeiro aumento no consumo energético da mobilidade. Por um lado, esse resultado parece contrariar a evidência geral encontrada na literatura. Por outro, é possível que esse resultado reflita maiores deseconomias de aglomeração (por exemplo devido a congestionamentos) nas cidades brasileiras, onde há grandes carências de sistemas de transporte público de massa e total ausência desses sistemas na grande maioria das cidades. Por fim, nós encontramos que os graus de conectividade e sinuosidade da malha viária não tiveram efeito significante sobre consumo de energia.

Este estudo possui algumas limitações. Uma delas é que não foi possível levar em conta o tamanho da oferta de serviços de transporte público devido a falta de dados. Pela mesma razão, não foi possível controlar as análises pelos níveis de congestionamento nas cidades. Este trabalho também não levou em consideração a dimensão de forma urbana relacionada ao grau de policentralidade e monocentralidade das cidades. Além disso, os resultados das regressões apresentadas encontram apenas o efeito médio de cada variável de forma urbana sobre o consumo de energia. No entanto, é razoável esperar que um aumento da densidade com a mesma magnitude possa ter impactos ambientais distintos caso esse aumento de densidade ocorra próximo a área

urbana central consolidada ou em áreas de expansão fragmentadas e distantes.

Futuros estudos serão necessários para investigar se o efeito da densidade sobre consumo energético da mobilidade é mesmo heterogêneo no espaço a partir de dados mais refinados de forma urbana e padrões de mobilidade na escala intrametropolitana. Com a publicação dos dados do próximo censo demográfico de 2022 no Brasil, novos estudos também poderiam investigar os efeitos da forma urbana sobre escolha de modos de transporte e sobre o tempo que as pessoas gastam no deslocamento casa-trabalho utilizando análises multinível. Existe também uma importante lacuna de pesquisa sobre como estimativas de acesso a oportunidades podem ajudar a compreender a relação entre forma urbana e mobilidade sustentável. Ainda, o DAG proposto neste trabalho é uma primeira versão e que deverá ser aprimorado, por exemplo, a partir da revisão dos caminhos causais atualmente delineados e da inclusão de novas variáveis relevantes, como a dimensão de policentralidade.

Os resultados deste estudo têm algumas implicações para políticas públicas. A forma urbana de uma cidade é um resultado de longo prazo da interação entre trajetórias de desenvolvimento econômico e condições geográficas e ambientais, mas também de um acumulado histórico de decisões políticas de planejamento urbano e de transportes. Nesse sentido, os resultados deste trabalho corroboram a necessidade de políticas que promovam padrões de crescimento urbano e ocupação do território menos dependentes do automóvel e mais favoráveis para que as pessoas possam usar e migrar para meios de transporte mais sustentáveis. Isso pode envolver, por exemplo, revisão de políticas de zoneamento para permitir maior mix de uso do solo, aumentando a proximidade entre áreas residenciais e ofertas de serviços e comércios. Governos locais também poderiam promover áreas urbanas mais sustentáveis revendo para cima limites de construção e coeficientes de aproveitamento para destravar o potencial construtivo em áreas próximas a terminais de transporte público e áreas urbanas centrais, onde há demanda reprimida. Outros instrumentos possíveis seriam aplicar cobrança de IPTU progressivo no tempo ou o Parcelamento, Edificação ou Utilização Compulsória (PEUC) sobre lotes e terrenos vazios próximos a essas áreas. Ambas estratégias permitiriam um crescimento urbano por meio de adensamento e preenchimento de áreas onde já existe infraestrutura urbana instalada ociosa ou subaproveitada, e que permite uma ocupação do solo com menor pressão ambiental e sobre sistemas de transporte.

Um aspecto central na revisão dessas políticas é a busca por maior coordenação do

planejamento urbano na escala metropolitana e entre políticas de transporte e uso do solo. Nesse sentido, se faz essencial repensar por exemplo os moldes da política habitacional no Brasil, que historicamente tem tido grande foco na construção em larga escala de conjuntos habitacionais em regiões afastadas e com baixa oferta de serviços e integração a outras áreas urbanas. Já há claras evidências de que esse modelo de política habitacional contribui para um crescimento urbano fragmentado (Biderman et al., 2018) e que torna a vida das pessoas mais dependentes do transporte motorizado (Pacheco, 2019).

Apesar de importantes, essas recomendações de política de uso do solo tendem a gerar impactos no médio e longo prazo. No entanto, existem também diversas políticas de transporte que governos locais podem adotar para ter efeitos de mais curto e médio prazo na promoção da mobilidade sustentável. É essencial a promoção de políticas que tornem o transporte público e o transporte ativo uma escolha viável e atrativa para as pessoas. Entre essas políticas, podemos citar o investimento em ciclovias, calçadas e sistemas de transporte de alta capacidade, subsídios ao transporte público e a construção de corredores exclusivos de ônibus. No entanto, isso não é suficiente. Também é necessário mudar a mentalidade de políticas que tentam acomodar a crescente demanda por uso de automóveis, e passar a implementar políticas que desencorajam o uso excessivo do automóvel (Cavoli, 2021; Mattioli & Colleoni, 2016). Isso envolve, por exemplo, cobrar estacionamentos em áreas públicas, cobrar circulação de automóveis em áreas centrais congestionadas, suspender novos projetos de construção de viadutos e alargamento de ruas e avenidas, diminuir o espaço viário dedicado a automóveis e eliminar a exigência mínima de oferta de vagas para automóveis em novos empreendimentos imobiliários. Alguns estudos apontam que esses desincentivos econômicos tendem a ser mais eficazes para desencorajar o uso do automóvel do que políticas de adensamento urbano (Duranton & Turner, 2018).

A forma de desenvolvimento espacial das cidades de hoje terá efeitos duradouros sobre os padrões de consumo de energia e de mobilidade sustentável que podem durar por décadas. A grande maioria das cidades brasileiras, salvo poucas exceções, não apresentam mais ritmos acelerados de crescimento populacional e econômico como observado em décadas passadas. Isso coloca menos pressão sobre um possível crescimento urbano descontrolado. Nesse contexto, as políticas locais de planejamento urbano e de transporte tem maior capacidade de influenciar o desenvolvimento espacial das cidades. No entanto, os efeitos dessas políticas sobre a forma urbana podem levar anos para ter um efeito real sobre forma urbana e mobilidade sustentável. Por isso, é fundamental pautar

hoje uma agenda de mobilidade sustentável como no planejamento territorial das cidades de amanhã.

REFERÊNCIAS

Ahlfeldt, G. M., & Pietrostefani, E. (2019). The economic effects of density: A synthesis. *Journal of Urban Economics*, *111*, 93–107. https://doi.org/10.1016/j.jue.2019.04.006

Angel, S., Blei, A. M., Parent, J., Lamson-Hall, P., Galarza-Sanchez, N., Civco, D. L., & Thom, K. (2016). Atlas of urban expansion—2016 edition. *New York: New York University, Nairobi: UN-Habitat, and Cambridge, MA: Lincoln Institute of Land Policy*, *1: Areas and densities*, 500.

ANP. (2021). *Dados estatísticos*. Agência Nacional do Petróleo, Gás Natural e Biocombustíveis. https://www.gov.br/anp/pt-br/centrais-de-conteudo/dados-estatisticos/dados-estatisticos

Artmann, M., Inostroza, L., & Fan, P. (2019). Urban sprawl, compact urban development and green cities. How much do we know, how much do we agree? *Ecological Indicators*, *96*, 3–9. https://doi.org/10.1016/j.ecolind.2018.10.059

Bagley, M. N., & Mokhtarian, P. L. (2002). The impact of residential neighborhood type on travel behavior: A structural equations modeling approach. *The Annals of Regional Science*, *36*(2), 279–297. https://doi.org/10.1007/s001680200083

Banister, D., Watson, S., & Wood, C. (1997). Sustainable Cities: Transport, Energy, and Urban Form. *Environment and Planning B: Planning and Design*, *24*(1), 125–143. https://doi.org/10.1068/b240125

Barrington-Leigh, C., & Millard-Ball, A. (2015). A century of sprawl in the United States. *Proceedings of the National Academy of Sciences*, *112*(27), 8244–8249. https://doi.org/10.1073/pnas.1504033112

Batty, M. (2018). *Inventing Future Cities*. MIT Press.

Bellemare, M. F., & Wichman, C. J. (2020). Elasticities and the Inverse Hyperbolic Sine Transformation. *Oxford Bulletin of Economics and Statistics*, *82*(1), 50–61. https://doi.org/10.1111/obes.12325

Bento, A. M., Cropper, M. L., Mobarak, A. M., & Vinha, K. (2005). The Effects of Urban Spatial Structure on Travel Demand in the United States. *The Review of Economics and Statistics*, *87*(3), 466–478. https://doi.org/10.1162/0034653054638292

Bettencourt, L., & West, G. (2010). A unified theory of urban living. *Nature*, *467*(7318), 912–913. https://doi.org/10.1038/467912a

Biderman, C., Hiromoto, M. H., & Ramos, F. R. (2018). *The Brazilian Housing Program Minha Casa Minha Vida: Effect on Urban Sprawl* (Working Paper WP18CB2). Lincoln Institute of Land Policy.

https://www.lincolninst.edu/sites/default/files/pubfiles/biderman_wp18cb2_0.pdf

Boarnet, M. G., & Sarmiento, S. (1998). Can Land-use Policy Really Affect Travel Behaviour? A Study of the Link between Non-work Travel and Land-use Characteristics. *Urban Studies*, *35*(7), 1155–1169. https://doi.org/10.1080/0042098984538

Boeing, G. (2017). OSMnx: New methods for acquiring, constructing, analyzing, and visualizing complex street networks. *Computers, Environment and Urban Systems*, *65*, 126–139. https://doi.org/10.1016/j.compenvurbsys.2017.05.004

Boeing, G. (2020). Planarity and street network representation in urban form analysis. *Environment and Planning B: Urban Analytics and City Science*, *47*(5), 855–869. https://doi.org/10.1177/2399808318802941

Bollen, K. A., & Pearl, J. (2013). Eight Myths About Causality and Structural Equation Models. Em S. L. Morgan (Org.), *Handbook of Causal Analysis for Social Research* (p. 301–328). Springer Netherlands. https://doi.org/10.1007/978-94-007-6094-3_15

Brownstone, D., & Golob, T. F. (2009). The impact of residential density on vehicle usage and energy consumption. *Journal of Urban Economics*, *65*(1), 91–98. https://doi.org/10.1016/j.jue.2008.09.002

Buehler, R. (2011). Determinants of transport mode choice: A comparison of Germany and the USA. *Journal of Transport Geography*, *19*(4), 644–657. https://doi.org/10.1016/j.jtrangeo.2010.07.005

Burton, E., Jenks, M., & Williams, K. (2003). *The Compact City: A Sustainable Urban Form?* Routledge.

Camagni, R., Gibelli, M. C., & Rigamonti, P. (2002). Urban mobility and urban form: The social and environmental costs of different patterns of urban expansion. *Ecological Economics*, *40*(2), 199–216. https://doi.org/10.1016/S0921-8009(01)00254-3

Cao, X. (Jason), Mokhtarian, P. L., & Handy, S. L. (2009). The relationship between the built environment and nonwork travel: A case study of Northern California. *Transportation Research Part A: Policy and Practice*, *43*(5), 548–559. https://doi.org/10.1016/j.tra.2009.02.001

Cao, X. (Jason), Næss, P., & Wolday, F. (2019). Examining the effects of the built environment on auto ownership in two Norwegian urban regions. *Transportation Research Part D: Transport and Environment*, *67*, 464–474. https://doi.org/10.1016/j.trd.2018.12.020

Cao, X., & Yang, W. (2017). Examining the effects of the built environment and residential self-selection on commuting trips and the related CO2 emissions: An empirical study in Guangzhou, China. *Transportation Research Part D: Transport and Environment*, *52*, 480–494. https://doi.org/10.1016/j.trd.2017.02.003

Castells-Quintana, D., Dienesch, E., & Krause, M. (2021). Air pollution in an urban world: A global view on density, cities and emissions. *Ecological Economics*, *189*, 107153. https://doi.org/10.1016/j.ecolecon.2021.107153

Cavoli, C. (2021). Accelerating sustainable mobility and land-use transitions in rapidly growing cities: Identifying common patterns and enabling factors. *Journal of Transport Geography*,

94, 103093. https://doi.org/10.1016/j.jtrangeo.2021.103093

Cervero, R. (2002). Built environments and mode choice: Toward a normative framework. *Transportation Research Part D: Transport and Environment*, *7*(4), 265–284. https://doi.org/10.1016/S1361-9209(01)00024-4

Cervero, R., & Kockelman, K. (1997). Travel demand and the 3Ds: Density, diversity, and design. *Transportation Research Part D: Transport and Environment*, *2*(3), 199–219. https://doi.org/10.1016/S1361-9209(97)00009-6

Cooke, S., & Behrens, R. (2017). Correlation or cause? The limitations of population density as an indicator for public transport viability in the context of a rapidly growing developing city. *Transportation Research Procedia*, *25*, 3003–3016. https://doi.org/10.1016/j.trpro.2017.05.229

Corbane, C., Pesaresi, M., Kemper, T., Politis, P., Florczyk, A. J., Syrris, V., Melchiorri, M., Sabo, F., & Soille, P. (2019a). Automated global delineation of human settlements from 40 years of Landsat satellite data archives. *Big Earth Data*, *3*(2), 140–169. https://doi.org/10.1080/20964471.2019.1625528

Corbane, C., Pesaresi, M., Kemper, T., Politis, P., Florczyk, A. J., Syrris, V., Melchiorri, M., Sabo, F., & Soille, P. (2019b). *GHSL Data Package 2019* (p. 140–169). Taylor & Francis. https://doi.org/10.1080/20964471.2019.1625528

Crane, R. (2000). The Influence of Urban Form on Travel: An Interpretive Review. *Journal of Planning Literature*, *15*(1), 3–23. https://doi.org/10.1177/08854120022092890

Creutzig, F., Baiocchi, G., Bierkandt, R., Pichler, P.-P., & Seto, K. C. (2015). Global typology of urban energy use and potentials for an urbanization mitigation wedge. *Proceedings of the National Academy of Sciences*, *112*(20), 6283–6288. https://doi.org/10.1073/pnas.1315545112

Cunningham, S. (2021). *Causal Inference: The Mixtape*. Yale University Press.

De Vos, J., Cheng, L., Kamruzzaman, Md., & Witlox, F. (2021). The indirect effect of the built environment on travel mode choice: A focus on recent movers. *Journal of Transport Geography*, *91*, 102983. https://doi.org/10.1016/j.jtrangeo.2021.102983

Des Rosiers, F., Thériault, M., Biba, G., & Vandersmissen, M.-H. (2017). Greenhouse gas emissions and urban form: Linking households' socio-economic status with housing and transportation choices. *Environment and Planning B: Urban Analytics and City Science*, *44*(5), 964–985. https://doi.org/10.1177/0265813516656862

Dijkstra, L., Florczyk, A. J., Freire, S., Kemper, T., Melchiorri, M., Pesaresi, M., & Schiavina, M. (2021). Applying the Degree of Urbanisation to the globe: A new harmonised definition reveals a different picture of global urbanisation. *Delineation of Urban Areas*, *125*, 103312. https://doi.org/10.1016/j.jue.2020.103312

Dijkstra, L., Poelman, H., & Veneri, P. (2019). *The EU-OECD definition of a functional urban area*. https://www.oecd-ilibrary.org/content/paper/d58cb34d-en

Ding, C., Wang, Y., Tang, T., Mishra, S., & Liu, C. (2018). Joint analysis of the spatial impacts of built environment on car ownership and travel mode choice. *Transportation Research Part*

D: Transport and Environment, *60*, 28–40. https://doi.org/10.1016/j.trd.2016.08.004

Duque, J. C., Lozano-Gracia, N., Patino, J. E., Restrepo, P., & Velasquez, W. A. (2019). Spatiotemporal dynamics of urban growth in Latin American cities: An analysis using nighttime light imagery. *Landscape and Urban Planning*, *191*, 103640. https://doi.org/10.1016/j.landurbplan.2019.103640

Duranton, G., & Puga, D. (2020). The Economics of Urban Density. *Journal of Economic Perspectives*, *34*(3), 3–26. https://doi.org/10.1257/jep.34.3.3

Duranton, G., & Turner, M. A. (2018). Urban form and driving: Evidence from US cities. *Journal of Urban Economics*, *108*, 170–191. https://doi.org/10.1016/j.jue.2018.10.003

EPE. (2020). *Balanço Energético Nacional—Séries Históricas Completas*. Empresa de Pesquisa Energética. https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/BEN-Series-Historicas-Completas

Estatísticas—Frota de Veículos—RENAVAM. (2021). Ministério da Infraestrutura. https://www.gov.br/infraestrutura/pt-br/assuntos/transito/conteudo-denatran/estatisticas-frota-de-veiculos-senatran

Ewing, R., & Cervero, R. (2001). Travel and the Built Environment: A Synthesis. *Transportation Research Record*, *1780*(1), 87–114. https://doi.org/10.3141/1780-10

Ewing, R., & Cervero, R. (2010). Travel and the Built Environment: A Meta-Analysis. *Journal of the American Planning Association*, *76*(3), 265–294. https://doi.org/10.1080/01944361003766766

Ewing, R., Hamidi, S., Gallivan, F., Nelson, A. C., & Grace, J. B. (2014). Structural equation models of VMT growth in US urbanised areas. *Urban Studies*, *51*(14), 3079–3096. https://doi.org/10.1177/0042098013516521

Ewing, R., Tian, G., Goates, J., Zhang, M., Greenwald, M. J., Joyce, A., Kircher, J., & Greene, W. (2015). Varying influences of the built environment on household travel in 15 diverse regions of the United States. *Urban Studies*, *52*(13), 2330–2348. https://doi.org/10.1177/0042098014560991

Florczyk, A. J., Corbane, C., Ehrlich, D., Freire, S., Kemper, T., Maffenini, L., Melchiorri, M., Pesaresi, M., Politis, P., Schiavina, M., Sabo, F., & Zanchetta, L. (2019). *GHSL Data Package 2019* (Publications Office of the European Union EUR 29788 EN). https://doi.org/10.2760/290498

Freeman, L. C. (1979). *Centrality in Social Networks: Conceptual Clarification*. https://www.bebr.ufl.edu/sites/default/files/Centrality in Social Networks.pdf

Gainza, X., & Livert, F. (2013). Urban Form and the Environmental Impact of Commuting in a Segregated City, Santiago de Chile. *Environment and Planning B: Planning and Design*, *40*(3), 507–522. https://doi.org/10.1068/b38045

Giacomin, D. J., & Levinson, D. M. (2015). Road network circuity in metropolitan areas. *Environment and Planning B: Planning and Design*, *42*(6), 1040–1053. https://doi.org/10.1068/b130131p

Glaeser, E. L., & Kahn, M. E. (2010). The greenness of cities: Carbon dioxide emissions and urban

development. *Journal of Urban Economics*, *67*(3), 404–418. https://doi.org/10.1016/j.jue.2009.11.006

Greenland, S., Pearl, J., & Robins, J. M. (1999). Causal Diagrams for Epidemiologic Research. *Epidemiology*, *10*(1), 37–48.

Guerra, E., & Li, M. (2021). The relationship between urban form and mode choice in US and Mexican cities: A comparative analysis of workers' commutes. *Journal of Transport and Land Use*, *14*(1), 441–462. https://doi.org/10.5198/jtlu.2021.1789

Hamidi, S., & Ewing, R. (2014). A longitudinal study of changes in urban sprawl between 2000 and 2010 in the United States. *Landscape and Urban Planning*, *128*, 72–82. https://doi.org/10.1016/j.landurbplan.2014.04.021

Handy, S. (1996). Methodologies for exploring the link between urban form and travel behavior. *Transportation Research Part D: Transport and Environment*, *1*(2), 151–165. https://doi.org/10.1016/S1361-9209(96)00010-7

Handy, S., Cao, X. (Jason), & Mokhtarian, P. (2005). Correlation or causality between the built environment and travel behavior? Evidence from Northern California. *Transportation Research Part D: Transport and Environment*, *10*(6), 427–444. https://doi.org/10.1016/j.trd.2005.05.002

Handy, S., Cao, X. (Jason), & Mokhtarian, P. L. (2006). Self-Selection in the Relationship between the Built Environment and Walking: Empirical Evidence from Northern California. *Journal of the American Planning Association*, *72*(1), 55–74. https://doi.org/10.1080/01944360608976724

Harari, M. (2020). Cities in Bad Shape: Urban Geometry in India. *American Economic Review*, *110*(8), 2377–2421. https://doi.org/10.1257/aer.20171673

He, C., Liu, Z., Gou, S., Zhang, Q., Zhang, J., & Xu, L. (2019). Detecting global urban expansion over the last three decades using a fully convolutional network. *Environmental Research Letters*, *14*(3), 034008. https://doi.org/10.1088/1748-9326/aaf936

Henderson, J. V., Nigmatulina, D., & Kriticos, S. (2019). Measuring urban economic density. *Journal of Urban Economics*, 103188. https://doi.org/10.1016/j.jue.2019.103188

Hong, J., & Shen, Q. (2013). Residential density and transportation emissions: Examining the connection by addressing spatial autocorrelation and self-selection. *Transportation Research Part D: Transport and Environment*, *22*, 75–79. https://doi.org/10.1016/j.trd.2013.03.006

Hong, J., Shen, Q., & Zhang, L. (2014). How do built-environment factors affect travel behavior? A spatial analysis at different geographic scales. *Transportation*, *41*(3), 419–440. https://doi.org/10.1007/s11116-013-9462-9

Horn, B. (1981). Hill shading and the reflectance map. *Proceedings of the IEEE*, *69*, 14–47. https://doi.org/10.1109/PROC.1981.11918

Huntington-Klein, N. (2021). *The Effect: An Introduction to Research Design and Causality* (1st edition). Chapman and Hall/CRC.

IBGE. (2010). *Censo demográfico 2010*.

https://ftp.ibge.gov.br/Censos/Censo_Demografico_2010/Resultados_do_Universo/Agregados_por_Setores_Censitarios/

IBGE, C. de G. (2016). *Arranjos populacionais e concentrações urbanas do Brasil* (2º ed). IBGE. https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=299700

IBGE, C. de G. (2017). *Áreas urbanizadas do Brasil: 2015* (Vol. 44). IBGE. https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=2100639

Ihlanfeldt, K. (2020). Vehicle miles traveled and the built environment: New evidence from panel data. *Journal of Transport and Land Use*, *13*(1), 23–48. https://doi.org/10.5198/jtlu.2020.1647

Inostroza, L., Baur, R., & Csaplovics, E. (2013). Urban sprawl and fragmentation in Latin America: A dynamic quantification and characterization of spatial patterns. *Journal of Environmental Management*, *115*, 87–97. https://doi.org/10.1016/j.jenvman.2012.11.007

Kang, J. E., Yoon, D. K., & Bae, H.-J. (2019). Evaluating the effect of compact urban form on air quality in Korea. *Environment and Planning B: Urban Analytics and City Science*, *46*(1), 179–200. https://doi.org/10.1177/2399808317705880

Keele, L., Stevenson, R. T., & Elwert, F. (2020). The causal interpretation of estimated associations in regression models. *Political Science Research and Methods*, *8*(1), 1–13. https://doi.org/10.1017/psrm.2019.31

Kühnert, C., Helbing, D., & West, G. B. (2006). Scaling laws in urban supply networks. *Physica A: Statistical Mechanics and Its Applications*, *363*(1), 96–103. https://doi.org/10.1016/j.physa.2006.01.058

Lee, C. (2020). Impacts of multi-scale urban form on PM2.5 concentrations using continuous surface estimates with high-resolution in U.S. metropolitan areas. *Landscape and Urban Planning*, *204*, 103935. https://doi.org/10.1016/j.landurbplan.2020.103935

Lee, S., & Bencekri, M. (2021). Chapter 17—Urban form and public transport design. Em C. Mulley & J. D. Nelson (Orgs.), *Urban Form and Accessibility* (p. 289–306). Elsevier. https://doi.org/10.1016/B978-0-12-819822-3.00018-3

Lee, S., & Lee, B. (2014). The influence of urban form on GHG emissions in the U.S. household sector. *Energy Policy*, *68*, 534–549. https://doi.org/10.1016/j.enpol.2014.01.024

Lee, S., & Lee, B. (2020). Comparing the impacts of local land use and urban spatial structure on household VMT and GHG emissions. *Journal of Transport Geography*, *84*, 102694. https://doi.org/10.1016/j.jtrangeo.2020.102694

Lemoine-Rodríguez, R., Inostroza, L., & Zepp, H. (2020). The global homogenization of urban form. An assessment of 194 cities across time. *Landscape and Urban Planning*, *204*, 103949. https://doi.org/10.1016/j.landurbplan.2020.103949

Liu, C., & Shen, Q. (2011). An empirical analysis of the influence of urban form on household travel and energy consumption. *Computers, Environment and Urban Systems*, *35*(5), 347–357. https://doi.org/10.1016/j.compenvurbsys.2011.05.006

Liu, Y., Song, Y., & Song, X. (2014). An empirical study on the relationship between urban compactness and CO2 efficiency in China. *Habitat International*, *41*, 92–98.

https://doi.org/10.1016/j.habitatint.2013.07.005

Lohrey, S., & Creutzig, F. (2016). A 'sustainability window' of urban form. *Transportation Research Part D: Transport and Environment*, *45*, 96–111. https://doi.org/10.1016/j.trd.2015.09.004

Mahendra, A., & Seto, K. C. (2019). *Upward and Outward Growth: Managing Urban Expansion for More Equitable Cities in the Global South* [Working Paper]. World Resources Institute.

Mahtta, R., Mahendra, A., & Seto, K. (2019). Building up or spreading out? Typologies of urban growth across 478 cities of 1 million+. *Environmental Research Letters*, *14*, 124077. https://doi.org/10.1088/1748-9326/ab59bf

Marquet, O., & Miralles-Guasch, C. (2015). The Walkable city and the importance of the proximity environments for Barcelona's everyday mobility. *Cities*, *42*, 258–266. https://doi.org/10.1016/j.cities.2014.10.012

Mattioli, G., & Colleoni, M. (2016). Transport Disadvantage, Car Dependence and Urban Form. Em P. Pucci & M. Colleoni (Orgs.), *Understanding Mobilities for Designing Contemporary Cities* (p. 171–190). Springer International Publishing. https://doi.org/10.1007/978-3-319-22578-4_10

McCarty, J., & Kaza, N. (2015). Urban form and air quality in the United States. *Landscape and Urban Planning*, *139*, 168–179. https://doi.org/10.1016/j.landurbplan.2015.03.008

McIntosh, J., Trubka, R., Kenworthy, J., & Newman, P. (2014). The role of urban form and transit in city car dependence: Analysis of 26 global cities from 1960 to 2000. *Transportation Research Part D: Transport and Environment*, *33*, 95–110. https://doi.org/10.1016/j.trd.2014.08.013

Merchán, D., Winkenbach, M., & Snoeck, A. (2020). Quantifying the impact of urban road networks on the efficiency of local trips. *Transportation Research Part A: Policy and Practice*, *135*, 38–62. https://doi.org/10.1016/j.tra.2020.02.015

Meurs, H., & Haaijer, R. (2001). Spatial structure and mobility. *Transportation Research Part D: Transport and Environment*, *6*(6), 429–446. https://doi.org/10.1016/S1361-9209(01)00007-4

Milakis, D., Cervero, R., & Wee, B. van. (2015). Stay local or go regional? Urban form effects on vehicle use at different spatial scales: A theoretical concept and its application to the San Francisco Bay Area. *Journal of Transport and Land Use*, *8*(2), Article 2. https://doi.org/10.5198/jtlu.2015.557

Montgomery, J. M., Nyhan, B., & Torres, M. (2018). How Conditioning on Posttreatment Variables Can Ruin Your Experiment and What to Do about It. *American Journal of Political Science*, *62*(3), 760–775. https://doi.org/10.1111/ajps.12357

Moreno-Monroy, A. I., Schiavina, M., & Veneri, P. (2021). Metropolitan areas in the world. Delineation and population trends. *Journal of Urban Economics*, *125*, 103242. https://doi.org/10.1016/j.jue.2020.103242

Muñiz, I., & Galindo, A. (2005). Urban form and the ecological footprint of commuting. The case of Barcelona. *Ecological Economics*, *55*(4), 499–514.

https://doi.org/10.1016/j.ecolecon.2004.12.008

Nadalin, V. G., Furtado, B. A., & Rabetti, M. (2018). Concentração intraurbana de população e empregos: Os centros antigos das cidades brasileiras perderam primazia? *Revista Brasileira de Estudos de População*, *35*(3), 1–24. https://doi.org/10.20947/S0102-3098a0043

Næss, P. (2015). Built Environment, Causality and Travel. *Transport Reviews*, *35*(3), 275–291. https://doi.org/10.1080/01441647.2015.1017751

Næss, P., Saglie, I.-L., & Richardson, T. (2020). Urban sustainability: Is densification sufficient? *European Planning Studies*, *28*(1), 146–165. https://doi.org/10.1080/09654313.2019.1604633

NASA JPL. (2013). NASA Shuttle Radar Topography Mission Global 1 arc second [Data set]. *NASA EOSDIS Land Processes DAAC*. https://doi.org/10.5067/MEaSUREs/SRTM/SRTMGL1.003

Pacheco, T. S. (2019). *Moradia, localização e o programa habitacional "Minha Casa Minha Vida" no município do Rio de Janeiro* [FGV]. http://bibliotecadigital.fgv.br/dspace/handle/10438/27253

Pearl, J. (1995). Causal diagrams for empirical research. *Biometrika*, *82*(4), 669–688. https://doi.org/10.1093/biomet/82.4.669

Pereira, R. H. M., Nadalin, V. G., Gonçalves, C. N., & Nascimento, I. F. do. (2019). *ODS 11: Tornar as cidades e os assentamentos humanos inclusivos, seguros, resilientes e sustentáveis* (Cadernos ODS: o que mostra o retrato do Brasil?). Ipea - Instituto de Pesquisa Econômica Aplicada. http://repositorio.ipea.gov.br/handle/11058/9340

Pesaresi, M., Huadong, G., Blaes, X., Ehrlich, D., Ferri, S., Gueguen, L., Halkia, M., Kauffmann, M., Kemper, T., Lu, L., Marin-Herrera, M. A., Ouzounis, G. K., Scavazzon, M., Soille, P., Syrris, V., & Zanchetta, L. (2013). A Global Human Settlement Layer From Optical HR/VHR RS Data: Concept and First Results. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *6*(5), 2102–2131. https://doi.org/10.1109/JSTARS.2013.2271445

Porta, S., Crucitti, P., & Latora, V. (2006). The Network Analysis of Urban Streets: A Primal Approach. *Environment and Planning B: Planning and Design*, *33*(5), 705–725. https://doi.org/10.1068/b32045

Reardon, S. F., & Firebaugh, G. (2002). Measures of Multigroup Segregation. *Sociological Methodology*, *32*(1), 33–67. https://doi.org/10.1111/1467-9531.00110

Ribeiro, H. V., Oehlers, M., Moreno-Monroy, A. I., Kropp, J. P., & Rybski, D. (2021). Association between population distribution and urban GDP scaling. *PLOS ONE*, *16*(1), e0245771. https://doi.org/10.1371/journal.pone.0245771

Roca, J. D. L., & Puga, D. (2017). Learning by Working in Big Cities. *The Review of Economic Studies*, *84*(1), 106–142. https://doi.org/10.1093/restud/rdw031

Rodríguez-Vignoli, J., & Rowe, F. (2018). How is internal migration reshaping metropolitan populations in Latin America? A new method and new evidence. *Population Studies*, *72*(2), 253–273. https://doi.org/10.1080/00324728.2017.1416155

Saeidizand, P., Fransen, K., & Boussauw, K. (2022). Revisiting car dependency: A worldwide analysis of car travel in global metropolitan areas. *Cities*, *120*, 103467. https://doi.org/10.1016/j.cities.2021.103467

Schwarz, N. (2010). Urban form revisited—Selecting indicators for characterising European cities. *Landscape and Urban Planning*, *96*(1), 29–47. https://doi.org/10.1016/j.landurbplan.2010.01.007

Silva, C., Reis, J. P., & Pinho, P. (2014). How Urban Structure Constrains Sustainable Mobility Choices: Comparison of Copenhagen and Oporto. *Environment and Planning B: Planning and Design*, *41*(2), 211–228. https://doi.org/10.1068/b37138

Silva, A. N. R. da, Costa, G. C. F., & Brondino, N. C. M. (2007). Urban sprawl and energy use for transportation in the largest Brazilian cities. *Energy for Sustainable Development*, *11*(3), 44–50. https://doi.org/10.1016/S0973-0826(08)60576-1

Sinnett, D., & Williams, K. (2021). Chapter 9—Urban form and walkable environments. Em C. Mulley & J. D. Nelson (Orgs.), *Urban Form and Accessibility* (p. 141–156). Elsevier. https://doi.org/10.1016/B978-0-12-819822-3.00015-8

Song, S., Diao, M., & Feng, C.-C. (2016). Individual transport emissions and the built environment: A structural equation modelling approach. *Transportation Research Part A: Policy and Practice*, *92*, 206–219. https://doi.org/10.1016/j.tra.2016.08.005

Song, Y., Merlin, L., & Rodriguez, D. (2013). Comparing measures of urban land use mix. *Computers, Environment and Urban Systems*, *42*, 1–13. https://doi.org/10.1016/j.compenvurbsys.2013.08.001

Stevens, M. R. (2017). Does Compact Development Make People Drive Less? *Journal of the American Planning Association*, *83*(1), 7–18. https://doi.org/10.1080/01944363.2016.1240044

Textor, J., Zander, B. van der, Gilthorpe, M. S., Liskiewicz, M., & Ellison, G. T. (2016). Robust causal inference using directed acyclic graphs: The R package "dagitty". *International Journal of Epidemiology*, *45*(6), 1887–1894. https://doi.org/10.1093/ije/dyw341

Travisi, C. M., Camagni, R., & Nijkamp, P. (2010). Impacts of urban sprawl and commuting: A modelling study for Italy. *Journal of Transport Geography*, *18*(3), 382–392. https://doi.org/10.1016/j.jtrangeo.2009.08.008

UN-Habitat. (2020). *World Cities Report 2020: The Value of Sustainable Urbanization*. United Nations Human Settlements Programme (UN-Habitat). https://unhabitat.org/sites/default/files/2020/10/wcr_2020_report.pdf

Van Acker, V., & Witlox, F. (2010). Car ownership as a mediating variable in car travel behaviour research using a structural equation modelling approach to identify its dual relationship. *Journal of Transport Geography*, *18*(1), 65–74. https://doi.org/10.1016/j.jtrangeo.2009.05.006

van de Coevering, P., & Schwanen, T. (2006). Re-evaluating the impact of urban form on travel patterns in Europe and North-America. *Transport Policy*, *13*(3), 229–239. https://doi.org/10.1016/j.tranpol.2005.10.001

White, M. J. (1986). Segregation and Diversity Measures in Population Distribution. *Population Index*, *52*(2), 198. https://doi.org/10.2307/3644339

Zegras, C. (2010). The Built Environment and Motor Vehicle Ownership and Use: Evidence from Santiago de Chile. *Urban Studies*, *47*(8), 1793–1817. https://doi.org/10.1177/0042098009356125

Zhao, P., Diao, J., & Li, S. (2017). The influence of urban structure on individual transport energy consumption in China's growing cities. *Habitat International*, *66*, 95–105. https://doi.org/10.1016/j.habitatint.2017.06.001

APÊNDICE A

TABELA DE RESULTADOS DA ANÁLISE FATORIAL

Tabela 1A. Resultados da análise de componentes principais dos indicadores de forma urbana de 182 aglomerações urbanas no Brasil, 2010.

Variáveis	**PC1**	**PC2**	**PC3**	**PC4**	**PC5**	**PC6**	**PC7**
Contiguidade	0,960	-0,044	0,001	-0,012	-0,046	0,151	-0,226
Compacidade	0,935	-0,039	0,029	0,028	-0,107	0,208	0,260
Sinuosidade vias	-0,061	0,988	-0,022	-0,108	0,043	-0,073	0,000
Conectividade vias	0,024	-0,021	0,996	-0,028	-0,069	0,048	0,002
Densidade populacional	0,024	-0,119	-0,030	0,960	0,240	0,066	0,002
Mix uso do solo	-0,110	0,048	-0,077	0,243	0,957	-0,062	-0,004
Densidade vias	0,583	-0,130	0,088	0,109	-0,096	0,784	0,005

Estatísticas	**PC1**	**PC2**	**PC3**	**PC4**	**PC5**	**PC6**	**PC7**
Soma cargas fatoriais ao quadrado	2,153	1,014	1,007	1,006	1,004	0,696	0,119
Proporção variância explicada	0,308	0,145	0,144	0,144	0,143	0,099	0,017
Variância acumulada	0,308	0,452	0,596	0,740	0,884	0,983	1,000

APÊNDICE B

TABELAS DE RESULTADOS DE TODOS MODELOS DE REGRESSÃO

Tabela A1. Efeitos médios de diferentes dimensões de forma urbana sobre o consumo de energia per capita no transporte individual motorizado. Áreas de Concentração Urbanas brasileiras, 2010.

	model_spec_all
(Intercept)	-15.075 [-21.286, -8.864] **
f_compact_contig_inter_dens	-0.579 [-0.792, -0.365] **
x_circuity_avg	0.771 [-1.535, 3.077]
x_density_pop_02km_2014	-0.127 [-0.264, 0.010] +
x_land_use_mix	-0.720 [-1.594, 0.153] +
x_normalized_closeness_centrality_avg	-0.049 [-0.251, 0.153]
x_mean_fleet_age	0.423 [-0.777, 1.623]
x_mean_slope	-0.046 [-0.219, 0.128]
x_pop_2010	-0.008 [-0.043, 0.027]
x_prop_dom_urban	1.489 [0.405, 2.572] *
x_prop_high_educ	-0.075 [-0.329, 0.178]
x_prop_razao_dep	-0.178 [-0.820, 0.464]
x_total_pop_growth_1990_2014	1.417 [-0.581, 3.416]
x_wghtd_mean_household_income_per_capita	0.926 [0.245, 1.606] *
I(x_pop_2010 * f_compact_contig_inter_dens)	0.049 [0.032, 0.067] **
Num.Obs.	182
R2	0.920
R2 Adj.	0.897
AIC	-143.1
BIC	-11.7
Log.Lik.	112.557
Std.Errors	by: i_name_region

Obs. significância estatística. + = 0.1, * = 0.05, ** = 0.01, *** = 0.001

Tabela A2. Efeito médio da sinuosidade da rede viária sobre o consumo de energia per capita no transporte individual motorizado. Áreas de Concentração Urbanas brasileiras, 2010.

	model_spec_circuity
(Intercept)	-8.898 [-11.699, -6.096] ***
x_circuity_avg	-4.765 [-9.469, -0.061] *
x_mean_slope	0.494 [0.103, 0.884] *
x_pop_2010	0.009 [-0.151, 0.169]
Num.Obs.	182
R2	0.140
R2 Adj.	0.125
AIC	215.2
BIC	228.0
Log.Lik.	-103.584
Std.Errors	by: i_name_region

Obs. significância estatística. + = 0.1, * = 0.05, ** = 0.01, *** = 0.001

Tabela A3. Efeito médio da closeness centrality sobre o consumo de energia per capita no transporte individual motorizado. Áreas de Concentração Urbanas brasileiras, 2010.

	model_spec_closenes1	model_spec_closenes2	model_spec_closenes3	model_spec_closenes4
(Intercept)	-15.151 [-17.315, -12.987] ***	-14.962 [-17.397, -12.528] ***	-8.147 [-8.792, -7.502] ***	-8.926 [-10.169, -7.684] ***
x_normalized_closeness_centrality_avg	0.024 [-0.095, 0.144]	0.033 [-0.095, 0.161]	0.086 [-0.506, 0.677]	1.155 [-0.214, 2.523] +
f_compact_contig_inter_dens	-0.552 [-0.801, -0.304] **	-0.569 [-0.776, -0.361] **	-0.875 [-1.499, -0.251] *	
x_mean_slope	-0.052 [-0.175, 0.070]	-0.049 [-0.171, 0.072]		
x_pop_2010	-0.107 [-0.129, -0.085] ***	-0.108 [-0.131, -0.085] ***	0.000 [-0.068, 0.069]	0.066 [-0.024, 0.155]
x_prop_dom_urban	1.351 [0.454, 2.248] *	1.352 [0.435, 2.269] *	1.875 [0.595, 3.156] *	
x_prop_razao_dep	-0.097 [-0.235, 0.041]			
x_wghtd_mean_household_income_per_capita	1.217 [0.856, 1.578] ***	1.213 [0.881, 1.545] ***		
I(x_pop_2010 * f_compact_contig_inter_dens)	0.047 [0.030, 0.064] **	0.048 [0.033, 0.064] ***	0.070 [0.022, 0.118] *	
x_prop_high_educ		0.028 [-0.282, 0.337]		
x_total_pop_growth_1990_2014				1.553 [-5.674, 8.781]
Num.Obs.	182	182	182	182
R2	0.821	0.821	0.866	0.112
R2 Adj.	0.813	0.813	0.839	0.097
AIC	-60.7	-60.7	-67.8	220.9
BIC	-31.9	-31.9	34.7	233.7
Log.Lik.	39.365	39.344	65.892	-106.460
Std.Errors	by: i_name_region	by: i_name_region	by: i_name_region	by: i_name_region

Obs. significância estatística. + = 0.1, * = 0.05, ** = 0.01, *** = 0.001

Tabela A4. Efeito médio da densidade experienciada sobre o consumo de energia per capita no transporte individual motorizado. Áreas de Concentração Urbanas brasileiras, 2010.

	model_spec_density
(Intercept)	-4.671 [-5.819, -3.523] ***
x_density_pop_02km_2014	-0.595 [-0.962, -0.227] *
x_pop_2010	0.108 [-0.041, 0.257]
x_prop_dom_urban	3.182 [2.769, 3.595] ***
Num.Obs.	182
R2	0.644
R2 Adj.	0.638
AIC	54.6
BIC	67.4
Log.Lik.	-23.288
Std.Errors	by: i_name_region

Obs. significância estatística. + = 0.1, * = 0.05, ** = 0.01, *** = 0.001

Tabela A5. Efeito médio do mix de uso do solo sobre o consumo de energia per capita no transporte individual motorizado. Áreas de Concentração Urbanas brasileiras, 2010.

	model_spec_landuse
(Intercept)	-7.365 [-9.179, -5.550] ***
x_land_use_mix	-2.309 [-4.508, -0.109] *
x_density_pop_02km_2014	-0.662 [-1.207, -0.116] *
x_pop_2010	0.290 [0.006, 0.573] *
Num.Obs.	182
R2	0.320
R2 Adj.	0.309
AIC	172.4
BIC	185.2
Log.Lik.	-82.185
Std.Errors	by: i_name_region

Obs. significância estatística. + = 0.1, * = 0.05, ** = 0.01, *** = 0.001

Tabela A6. Efeito médio do fator compacidade-contiguidade-densidade de interseções sobre o consumo de energia per capita no transporte individual motorizado. Áreas de Concentração Urbanas brasileiras, 2010.

	model_spec_fcompact1	model_spec_fcompact2	model_spec_fcompact3	model_spec_fcompact4
(Intercept)	-15.151 [-17.315, -12.987] ***	-14.962 [-17.397, -12.528] ***	-8.147 [-8.792, -7.502] ***	-9.339 [-10.664, -8.013] ***
f_compact_contig_inter_dens	-0.552 [-0.801, -0.304] **	-0.569 [-0.776, -0.361] **	-0.875 [-1.499, -0.251] *	-1.057 [-2.773, 0.659]
x_mean_slope	-0.052 [-0.175, 0.070]	-0.049 [-0.171, 0.072]		
x_normalized_closeness_centrality_avg	0.024 [-0.095, 0.144]	0.033 [-0.095, 0.161]	0.086 [-0.506, 0.677]	
x_pop_2010	-0.107 [-0.129, -0.085] ***	-0.108 [-0.131, -0.085] ***	0.000 [-0.068, 0.069]	0.063 [-0.012, 0.139] +
x_prop_dom_urban	1.351 [0.454, 2.248] *	1.352 [0.435, 2.269] *	1.875 [0.595, 3.156] *	
x_prop_razao_dep	-0.097 [-0.235, 0.041]			
x_wghtd_mean_household_income_per_capita	1.217 [0.856, 1.578] ***	1.213 [0.881, 1.545] ***		
I(x_pop_2010 * f_compact_contig_inter_dens)	0.047 [0.030, 0.064] **	0.048 [0.033, 0.064] ***	0.070 [0.022, 0.118] *	0.081 [-0.035, 0.197]
x_prop_high_educ		0.028 [-0.282, 0.337]		
x_total_pop_growth_1990_2014				2.788 [-4.891, 10.466]
Num.Obs.	182	182	182	182
R2	0.821	0.821	0.866	0.049
R2 Adj.	0.813	0.813	0.839	0.028
AIC	-60.7	-60.7	-67.8	235.5
BIC	-31.9	-31.9	34.7	251.5
Log.Lik.	39.365	39.344	65.892	-112.728
Std.Errors	by: i_name_region	by: i_name_region	by: i_name_region	by: i_name_region

Obs. significância estatística. + = 0.1, * = 0.05, ** = 0.01, *** = 0.001