UNIVERSIDADE DE SÃO PAULO
ESCOLA POLITÉCNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

MARCELO NAKANO DANIEL

Leis de escala aplicadas para os municípios brasileiros

São Paulo

2019

MARCELO NAKANO DANIEL

Leis de escala aplicadas para os municípios brasileiros

Dissertação apresentada à Escola Politécnica
da Universidade de São Paulo para obtenção
do título de Mestre em Ciências.

Área de concentração: Engenharia de
Construção Civil e Urbana

Orientador: Prof. Dr. Alex Kenya Abiko

São Paulo

2019

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

Este exemplar foi revisado e corrigido em relação à versão original, sob responsabilidade única do autor e com a anuência de seu orientador.

São Paulo, _____ de _____ de _____

Assinatura do autor: _____

Assinatura do orientador: _____

Catálogo-na-publicação

Daniel, Marcelo Nakano

Leis de escala aplicadas para os municípios brasileiros / M. N. Daniel --
versão corr. -- São Paulo, 2019.

111 p.

Dissertação (Mestrado) - Escola Politécnica da Universidade de São
Paulo. Departamento de Engenharia de Construção Civil.

1.Cidades 2.Indicadores de desempenho I.Universidade de São Paulo.
Escola Politécnica. Departamento de Engenharia de Construção Civil II.t.

Agradecimentos

Agradeço primeiramente à Universidade de São Paulo e à Escola Politécnica pela estrutura disponibilizada para realização da pesquisa. Agradeço em especial aos funcionários da Escola Politécnica pelo trabalho competente e ajuda na solução de diversos problemas e questões do dia a dia.

Em segundo lugar agradeço à professora Karin Castro pela orientação na elaboração do meu projeto de pesquisa e na condução da fase inicial. Agradeço também ao professor Alex Abiko pela orientação e disponibilidade ao longo de toda a pesquisa.

Por último, gostaria de agradecer aos meus pais, familiares e amigos que sempre demonstraram apoio incondicional e estiveram presentes em todos os momentos importantes durante o período de realização dessa pesquisa.

Resumo

DANIEL, Marcelo Nakano. **Leis de escala aplicadas para os municípios brasileiros**. 2019. 111 f. Dissertação (Mestrado em Ciências) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2019.

Leis de escala aplicadas a cidades já foram identificadas para diversos contextos ao redor do mundo e sua validade defendida por diversos autores. A invariância em escala e as relações de crescimento superlinear, linear e sublinear foram observadas considerando-se a relação entre diversos indicadores (sociais, econômicos, infraestrutura) e o tamanho das cidades.

Nesta pesquisa foi avaliada a aplicação das leis de escala para as cidades brasileiras em relação a 14 indicadores dos Censos do Instituto Brasileiro de Geografia e Estatística (IBGE) que se alinham com indicadores da Norma ISO 37120:2017. As leis de escala foram avaliadas para esses indicadores em relação ao tamanho populacional das cidades brasileiras por meio do levantamento e processamento dos dados disponíveis. Não foi possível confirmar a generalidade da aplicação dessas leis, sendo apontadas as suas limitações.

Palavras-chaves: cidades, sistemas complexos, leis de escala, urbanização, indicadores urbanos.

Abstract

DANIEL, Marcelo Nakano. **Scaling laws applied to Brazilian cities**. 2019. 111 p. Dissertation (Master of Science) – Escola Politécnica, University of São Paulo, São Paulo, 2019.

Scaling laws applied to cities have already been identified for diverse contexts around the world and their validity defended by several authors. The scale invariance and the super-linear, linear and sublinear growth behaviors were observed considering the relationship between several indicators (social, economic, infrastructure) and the size of the cities.

This research evaluated the applicability of the scaling laws for Brazilian cities relative to 14 indicators from Instituto Brasileiro de Geografia e Estatística (IBGE) Censuses that are aligned with indicators proposed by ISO 37120: 2017 norm. The scaling laws were evaluated for these indicators in relation to the population size of Brazilian cities through the collection and processing of available data. It was not possible to confirm the generality of the application of these laws, and their limitations were pointed out.

Keywords: cities, complex systems, scaling laws, urbanization, urban indicators.

Lista de figuras

Figura 1 – População total, urbana e rural no mundo.	11
Figura 2 – População total, urbana e rural no Brasil.	12
Figura 3 – Relação entre a taxa metabólica basal e a massa corporal para diversos animais.	21
Figura 4 – Leis de escala em cidades dos Estados Unidos	26
Figura 5 – Frequência cardíaca dos animais e o velocidade da caminhada nas cidades	26
Figura 6 – Identificação das cidades de acordo com as regiões a que pertencem . .	42
Figura 7 – Identificação das cidades pertencentes à Região Metropolitana de São Paulo	43
Figura 8 – Identificação das capitais de cada estado	43
Figura 9 – Identificação das cidades pertencentes ao estado de São Paulo	44
Figura 10 – Sequência de operações realizadas no programa	45
Figura 11 – Indicador: Pessoas com acesso a saneamento básico	49
Figura 12 – Indicador: Anos vividos	50
Figura 13 – Indicador: Mortes até 5 anos de idade	51
Figura 14 – Indicador: Pessoas em moradia precária	52
Figura 15 – Indicador: Pessoas extremamente pobres	53
Figura 16 – Indicador: Pessoas com acesso à água encanada	54
Figura 17 – Indicador: Desempregados	55
Figura 18 – Indicador: Jovens desempregados	56
Figura 19 – Indicador: Crianças e jovens na escola	57
Figura 20 – Indicador: Pessoas com ensino fundamental	58
Figura 21 – Indicador: Pessoas com acesso à coleta de lixo	59
Figura 22 – Indicador: Pessoas com abastecimento de energia	60
Figura 23 – Indicador: Pessoas com ensino médio	61
Figura 24 – Indicador: Pessoas com ensino superior	62
Figura 25 – Variação de β e R^2 para o indicador <i>Pessoas com acesso a saneamento básico</i>	63
Figura 26 – Variação de β e R^2 para o indicador <i>Anos vividos</i>	64
Figura 27 – Variação de β e R^2 para o indicador <i>Mortes até 5 anos de idade</i>	65

Figura 28 – Variação de β e R^2 para o indicador <i>Pessoas em moradia precária</i> . . .	66
Figura 29 – Variação de β e R^2 para o indicador <i>Pessoas extremamente pobres</i> . . .	67
Figura 30 – Variação de β e R^2 para o indicador <i>Pessoas com acesso à água encanada</i>	68
Figura 31 – Variação de β e R^2 para o indicador <i>Desempregados</i>	69
Figura 32 – Variação de β e R^2 para o indicador <i>Jovens desempregados</i>	70
Figura 33 – Variação de β e R^2 para o indicador <i>Crianças e jovens na escola</i>	71
Figura 34 – Variação de β e R^2 para o indicador <i>Pessoas com ensino fundamental</i> .	72
Figura 35 – Variação de β e R^2 para o indicador <i>Pessoas com acesso à coleta de lixo</i>	73
Figura 36 – Variação de β e R^2 para o indicador <i>Pessoas com abastecimento de</i> <i>energia</i>	74
Figura 37 – Variação de β e R^2 para o indicador <i>Pessoas com ensino médio</i>	75
Figura 38 – Variação de β e R^2 para o indicador <i>Pessoas com ensino superior</i> . . .	76

Lista de tabelas

Tabela 1 – Indicadores utilizados do Censo e os indicadores correspondentes presentes na Norma NBR ISO 37120:2017	38
Tabela 2 – Indicadores utilizados do Censo e os correspondentes nomes utilizados .	39
Tabela 3 – Valores calculados de β e R^2 para os indicadores utilizados, para os Censos de 1991, 2000 e 2010, para os municípios brasileiros com mais de 50 mil habitantes	47
Tabela 5 – Indicadores utilizados do Censo e suas definições	111

Lista de abreviaturas e siglas

ABNT	Associação Brasileira de Normas Técnicas
IBGE	Instituto Brasileiro de Geografia e Estatística
ISO	International Organization for Standardization
NBR	Norma Brasileira
PIB	Produto Interno Bruto

Sumário

1	Introdução	11
2	Objetivos	16
3	Método	18
4	Os sistemas complexos e as leis de escala	19
4.1	<i>As leis de escala aplicadas às cidades</i>	23
4.2	<i>As leis de escala para as cidades brasileiras</i>	35
4.3	<i>Indicadores utilizados</i>	37
4.4	<i>Tratamento dos dados e produção de gráficos e tabelas</i>	39
4.4.1	dictionary.py	40
4.4.2	data_conversion.py	41
4.4.3	parameters.py	42
4.4.4	read_plot_data.py	44
5	Resultados	46
5.1	<i>Resultados para os indicadores x população, para o Censos de 1991, 2000 e 2010</i>	46
5.2	<i>Varição de β e R^2 para cada indicador segundo a população mínima considerada, para os Censos de 1991, 2000 e 2010</i>	47
6	Considerações finais	77
	Referências	84
	Anexo A – Código do arquivo <i>read_plot_data.py</i>	87
	Anexo B – Indicadores da Norma ABNT NBR ISO 37120:2017	107
	Anexo C – Definição dos indicadores utilizados do Censo . . .	111

1 Introdução

Cada vez uma parcela maior da população mundial vive em cidades. Estima-se que em 2050 mais de 66% da população mundial estará vivendo em aglomerações urbanas, sendo que a maior contribuição para os elevados acréscimos nas taxas de urbanização será originada nos países pobres e em desenvolvimento, pois muitos deles ainda apresentam grande parcela da população vivendo em áreas rurais. Os países desenvolvidos, por outro lado, já apresentam elevada parcela da população vivendo em áreas urbanas, alguns com percentuais superiores a 95% de população urbana. No Brasil, em 2010, quase 85% da população já vivia nas cidades (IBGE, 2012)¹.

A figura 1 mostra como a população urbana cresceu no mundo de 1950 até hoje e projeções de como este crescimento se dará até 2050. A figura 2 mostra o mesmo para o Brasil.

Figura 1 – População total, urbana e rural no mundo.

Fonte: UN (2018)

¹ O IBGE pretende utilizar uma nova metodologia para a caracterização de áreas urbanas no Brasil. Segundo esta nova metodologia, a população urbana do Brasil em 2010 passaria dos cerca de 85% para 76%. Densidade demográfica, localização em relação aos principais centros urbanos e tamanho da população serão os critérios fundamentais da nova metodologia, que ainda está em debate (IBGE, 2017).

Figura 2 – População total, urbana e rural no Brasil.

Fonte: UN (2018)

Esses dados mostram com clareza o acelerado crescimento da população urbana, a qual representa uma parcela cada vez mais significativa da população total. Além disso, os prognósticos revelam uma tendência importante para as próximas décadas: seja pelo crescimento das cidades já existentes ou pelo surgimento de novas áreas urbanas, cada vez mais pessoas serão impactadas pelas transformações que ocorrem nas cidades, assim como também será cada vez maior o impacto produzido pelas cidades no mundo. Makse et al. (1998) observam que já houve inúmeras tentativas de utilização de instrumentos para se limitar o crescimento das cidades, os quais não foram eficientes e eficazes. Ou seja, o crescimento da urbanização parece ser um caminho sem volta.

Se, por um lado, as cidades muitas vezes são vistas como o “lugar das oportunidades, do desenvolvimento e progresso” (é onde há grande oferta de empregos qualificados, produção intensa de conhecimento e inovação, oferta de serviços variados), são nelas também onde se originam graves problemas sociais e ambientais antes inexistentes ou pouco relevantes nas áreas rurais, como o aumento das taxas de violência, propagação de doenças, poluição, problemas de mobilidade (BETTENCOURT et al., 2007). A vantagem urbana de interligar as pessoas pode ficar comprometida pelos congestionamentos, pelo crime, pela propagação de doenças, pela produção de lixo. Os congestionamentos prejudicam a produtividade e fazem com que as pessoas desperdicem uma quantidade de tempo importante do seu dia em suas viagens diárias. O medo mantém as pessoas por trás de portas trancadas, separadas umas das outras e das vantagens da vida na cidade, algo

bastante comum em grandes centros urbanos como São Paulo. A propagação de doenças torna-se mais rápida devido ao aumento do contato entre as pessoas e ao maior tempo despendido em ambientes fechados. Em suma, da mesma forma que a proximidade entre as pessoas propicia a propagação de ideias, ela também causa a propagação de doenças, o aumento da criminalidade, da produção de lixo e de problemas ambientais (GLAESER, 2011).

A crescente urbanização, não apenas no Brasil, mas no mundo de maneira geral, tem diversos impactos na sociedade e no planeta em que vivemos. As cidades possuem uma natureza bastante dual em relação a diversas questões. Elas atraem, por exemplo, algumas das pessoas mais ricas e mais pobres do mundo. É necessário se ter a clareza das consequências do crescimento urbano e do adensamento populacional. Os benefícios de aproximar as pessoas vêm atrelados a muitos perigos, vários deles bastante conhecidos.

O processo de urbanização provoca danos ao meio ambiente como a diminuição da cobertura vegetal, ao aumento da poluição, à produção de lixo, diminuição da biodiversidade, etc. Fuller e Gaston (2009) apontam, por exemplo, para o acelerado declínio dos espaços verdes com o crescimento das cidades, o que aumenta o isolamento das pessoas e das oportunidades da experiência com a natureza. A diminuição do contato com a biodiversidade pode, assim, ser considerada uma diminuição da qualidade de vida nas cidades. Por outro lado, é nas próprias cidades onde as interações entre o homem, o ambiente urbano e a natureza podem ser estudados e compreendidos na busca por um futuro sustentável para as cidades (GRIMM et al., 2008).

As cidades são caracterizadas por diversos problemas, todavia é nelas mesmas onde se encontra o potencial produtor de soluções desses mesmos problemas, visto que são o centro da criatividade, poder e riqueza. Elas podem amplificar os pontos fortes da humanidade, afinal, o maior talento de nossa espécie é a capacidade de aprender uns com os outros, e aprendemos de maneira mais profunda e completa quando estamos frente a frente (GLAESER, 2011). Problemas de segurança podem ser combatidos quando numa cidade se tem uma nítida separação entre o espaço público e o espaço privado, quando existem “os olhos da rua” e quando a calçada tem pessoas transitando ininterruptamente (JACOBS, 2011). O transporte público eficiente contribui para o combate aos problemas de mobilidade. Soluções tecnológicas podem mitigar problemas decorrentes da produção de lixo e poluição.

O aumento da quantidade de dados disponível sobre as realidades urbanas possibilita o aprofundamento do conhecimento sobre as cidades. Aprofunda-se não apenas o melhor entendimento sobre os impactos da vida urbana sobre o homem como também é possível que ferramentas sejam criadas para mitigar os problemas urbanos e potencializar os benefícios das aglomerações urbanas.

Dada a importância que as cidades têm e que vêm ganhando na vida das pessoas e no mundo, é fundamental a construção de conhecimento que busque aprimorar o entendimento sobre como se dão os seus processos de formação, de expansão, de crescimento e de suas dinâmicas. Uma melhor compreensão desses aspectos permite a estruturação de ações e a produção de planejamento de curto, médio e longo prazos visando, por um lado, a mitigação dos problemas urbanos e, por outro lado, a potencialização dos benefícios que as cidades trazem para as pessoas.

A construção de um entendimento cientificamente embasado da dinâmica, crescimento e organização das cidades, pode ser feita adotando-se uma abordagem integrada, quantitativa e preditiva, baseada no conhecimento científico. Para combater as grandes ameaças, como o aquecimento global, produção de lixo, violência urbana, deve ser desenvolvida uma teoria abrangente e unificada de sustentabilidade, tendo as cidades e a urbanização no seu centro (BETTENCOURT; WEST, 2010).

Para que se tenha certa previsibilidade e para que se possa fazer planejamentos de curto, médio e longo prazos, é necessário ter o entendimento sobre as consequências de ações sobre os espaços urbanos e sobre as pessoas, considerando-se as mais variadas facetas das cidades. Essas facetas incluem os diversos atores da sociedade (cidadãos, políticos, empresários, organizações da sociedade civil) e os temas mais diversos (mobilidade, gestão, meio ambiente, segurança).

As interações existentes num sistema dessa natureza acontecem de maneira integrada, produzindo não linearidades e dinâmicas que muitas vezes não são intuitivas. Essas características são típicas de sistemas complexos, dos quais teorias e abordagens podem ser utilizadas para identificar e caracterizar o universo das cidades, suas características e suas dinâmicas. Uma abordagem utilizando as teorias dos sistemas complexos pode contribuir com intervenções mais eficientes, com maior previsibilidade sobre as consequências de determinadas ações e com uma visão mais integrada da vida urbana (FURTADO; SAKOWSKI; TÓVOLLI, 2015).

Um dos aspectos abordados nas teorias dos sistemas complexos é a escalabilidade, que descreve como uma propriedade de um sistema muda se uma outra propriedade desse sistema se altera. Na biologia a escalabilidade já foi investigada e bem descrita, por exemplo, para a relação entre o consumo de energia médio por um organismo em repouso - taxa metabólica basal - e a massa corporal desse organismo (MITCHELL, 2009). A partir da descrição e caracterização da escalabilidade na biologia é possível prever a quantidade de energia demanda por um ser vivo sabendo-se o valor de sua massa corporal. Essa escalabilidade se traduz em leis de escala, descrições matemáticas desse fenômeno.

Fazendo-se um paralelo com os estudos urbanos, entender a escalabilidade para o universo das cidades significa entender como suas propriedades se modificam com a mudança do seu tamanho. Em outras palavras, seria possível prever como cidades de determinados portes se comportam conhecendo-se as propriedades de cidades de outros tamanhos. Ou, ainda, fazer projeções futuras sobre as características de uma cidade em crescimento.

No caso das cidades, as características investigadas podem ser representadas por indicadores, como indicadores relacionados à educação, saúde, meio ambiente, violência. Entender a escalabilidade, neste caso, significa entender como esses indicadores se alteram com as variações dos tamanhos das cidades e entender a validade das leis de escala para os fenômenos urbanos.

2 Objetivos

Esta pesquisa apresenta uma análise sobre as leis de escala aplicadas às cidades brasileiras. As leis de escala fazem parte das teorias do campo de conhecimento conhecido como sistemas complexos.

Esta pesquisa foca no estudo das cidades brasileiras por meio de uma abordagem científica e interdisciplinar. Científica, pois buscou-se compreender e estabelecer relações explicativas para as dinâmicas urbanas (relações entre o crescimento das cidades e impacto em seus habitantes) por meio da identificação e análise de diversos conjuntos de dados e fenômenos resultantes da urbanização. Interdisciplinar, porque, para a explicação dessas dinâmicas, buscou modelos, relações e comportamentos já conhecidos em outras ciências (como biologia, ecologia, teoria de redes) e que explicam fenômenos semelhantes ou análogos aos que ocorrem com as cidades. Fenômenos conhecidos e já bastante estudados como a escalabilidade no campo da biologia, a interação entre espécies num ecossistema no campo da ecologia e o crescimento das redes no campo da teoria de redes, são exemplos de fenômenos com teorias já estabelecidas em outras ciências e que podem ser aplicados para o campo do urbanismo. Nesta pesquisa foi dado enfoque exclusivamente às cidades brasileiras.

Apesar das metrópoles e cidades brasileiras terem sido construídas em contextos socioeconômicos, históricos e geográficos diferentes, observam-se em seus territórios diversas características semelhantes. Villaça (1998), por exemplo, identifica processos de transformação do espaço comuns às metrópoles brasileiras, como a concentração da burguesia em determinadas regiões das cidades e a distribuição não uniforme da oferta de infraestrutura. De maneira semelhante, Deák (1991) aponta que o tipo de espaço urbano produzido pela sociedade brasileira está intimamente ligado às características dessa sociedade. Ou seja, as cidades brasileiras, apesar de condicionadas a diferentes fatores na sua construção, podem apresentar diversas características comuns.

Uma vez que é possível existirem semelhanças entre cidades tão diferentes no território brasileiro, procurou-se nesta pesquisa observar se as leis de escala podem ser aplicadas para o conjunto das cidades brasileiras. Isto é particularmente importante quando se observam fenômenos como a economia de escala para a infraestrutura, por exemplo. É de relevância também o caso inverso à economia de escala, no qual se enquadra a proliferação

de doenças, por exemplo. Economia de escala com respeito à infraestrutura quer dizer que as cidades maiores apresentam menor demanda de determinada infraestrutura por habitante do que cidades menores. Um das explicações para este fato é a estruturação de redes que a tornam mais eficiente. Contrariamente, nas cidades maiores há proliferação mais acelerada de doenças, uma vez que há maior interação entre os indivíduos.

A identificação de tais fenômenos pode contribuir de diversas maneiras para o planejamento e gestão urbanos e pode ser usada como subsídio na tomada de decisões nos processos de transformação das cidades. Se, por um lado, economia de escala relativa à infraestrutura pode ser vista como sendo positiva, visto que ela implica demanda de recursos (materiais e financeiros) que cresce numa proporção mais lenta que o tamanho populacional das cidades, por outro, o aumento de taxas como a da violência é um ônus que também deve ser considerado no processo de expansão e adensamento urbanos. Entender a validade das leis de escala, quantificá-las para os diversos indicadores e identificar seus impactos na população é fundamental para a construção de um maior entendimento sobre os fenômenos urbanos. A tomada de decisões e ações tem, assim, mais suporte para que a construção e reestruturação de nossas cidades torne-se mais sustentável.

Embora já exista considerável literatura acerca das leis de escala para cidades em diversos países, este tipo de abordagem para a realidade brasileira ainda há que ser bastante explorada. Além disso, não há consenso sobre a generalidade e validade das leis de escala aplicadas às cidades, tampouco sobre definições precisas sobre como este tipo de análise deve ser conduzida. Há, portanto, lacunas a serem preenchidas e muitas perguntas a serem respondidas. A investigação aqui conduzida sobre as leis de escala nas cidades brasileiras em relação a diversos indicadores objetiva entender como se dá a relação desses indicadores como dependência do tamanho populacional para diversas cidades. Com este trabalho pretende-se, em última análise, verificar a validade das leis de escala para as cidades brasileiras e entender suas consequências e limitações.

3 Método

O passo inicial para a construção da análise das leis de escala aplicadas às cidades brasileiras foi a realização de revisão da literatura. Foi feita uma busca pela produção científica existente que abordasse as leis de escala para diversas realidades (conjuntos de cidades de diversos países). A partir da revisão bibliográfica e da pesquisa sobre a disponibilidade de dados para a realidade brasileira, foi feita a escolha dos indicadores a serem utilizados na análise.

Como fonte principal de dados foram escolhidos os Censos do Instituto Brasileiro de Geografia e Estatística (IBGE), uma vez que eles dispõem de informações e dados sobre todos os municípios brasileiros. Os dados para todos os municípios brasileiros constantes nos Censos do IBGE de 1991, 2000 e 2010 foram levantados e tabulados.

Para limitar o escopo da análise, foi feita a escolha apenas de um número limitado de indicadores dos Censos. Os indicadores utilizados foram aqueles que mais se assemelhavam aos indicadores descritos na Norma ABNT NBR ISO 37120:2017 - Desenvolvimento sustentável de comunidades (ABNT, 2017). Esta norma descreve, a partir de um enfoque global, indicadores para serviços urbanos e qualidade de vida.

A Norma ABNT NBR ISO 37120:2017 é uma adequação da Norma ISO 37120:2014 - Sustainable development of communities à realidade brasileira. Ela foi resultado de um processo participativo e multidisciplinar para adaptação. Seu intuito principal é estabelecer critérios claros para se medir o desempenho das cidades em suas diversas facetas, para que as melhores práticas possam ser identificadas, para que as mais diversas cidades possam ser comparadas e para que sejam possíveis avaliações ao longo do tempo (NEGREIROS; ABIKO, 2019). Entre os indicadores presentes na Norma ABNT NBR ISO 37120:2017, estão indicadores da economia, educação, energia, saúde, segurança, habitação, transporte, água e saneamento, entre outros.

Os dados tabulados foram, então, processados utilizando-se a linguagem de programação *Python*. Os *scripts* escritos em *Python* foram a ferramenta que possibilitou o trabalho com a grande quantidade de dados utilizada. Eles são um dos produtos desta pesquisa. O outro produto é resultado da utilização dos *scripts*, a partir dos quais foi possível a produção de gráficos e o cálculo dos valores de dois importantes parâmetros (β e R^2) para avaliação das leis de escala.

4 Os sistemas complexos e as leis de escala

Um sistema complexo pode ser definido como um sistema em que uma extensa rede de componentes sem coordenação ou controle central e com simples regras de operação dão origem a comportamentos coletivos complexos. Eles apresentam um sofisticado processamento de informações, do qual se utilizam para aprender, se adaptar e evoluir. Uma definição alternativa, mas que contém as mesmas ideias básicas é a de que um sistema complexo é um sistema que exhibe comportamentos emergentes e auto-organizações não triviais (MITCHELL, 2009).

Assim, podem ser elencadas as seguintes características dos sistemas complexos:

- Comportamento coletivo complexo
- Processamento de informação
- Adaptação

Um *comportamento coletivo complexo* se origina da existência de grandes redes compostas por indivíduos, cada um seguindo regras relativamente simples sem que haja um controle centralizado, sem um líder. As ações coletivas de um vasto número de componentes dão origem a padrões complexos emergentes, não intuitivos e que mudam com o tempo.

Quando se fala em *processamento de informação* dos sistemas complexos, quer-se dizer que esses sistemas produzem e utilizam informações, tanto informações internas quanto informações externas (do meio em que se encontram).

Por fim, *adaptação* quer dizer que todos esses sistemas se adaptam, isto é, mudam o comportamento ao longo do tempo de acordo com o processamento de informações, o que aumenta as chances de sobrevivência e sucesso, num processo de aprendizado evolutivo.

Os sistemas complexos, em linhas gerais, são um campo de conhecimento que agrega de maneira interdisciplinar teorias de diversas áreas, como a física, matemática, teorias de redes, biologia, sociologia. Um dos objetivos principais das teorias de sistemas complexos é o entendimento de comportamentos emergentes, os quais surgem da ação e interação dos indivíduos (MITCHELL, 2009).

Um exemplo do caráter interdisciplinar deste campo é a proposição do modelo de Boltzmann-Lotka-Volterra para explicar a formação espacial das cidades (WILSON, 2008). Este modelo envolve a aplicação de formulações bem estabelecidas da Física Estatística (equações da termodinâmica de Boltzmann) associadas a formulações igualmente bem

estabelecidas provenientes da Ecologia (equações de concorrência entre espécies de Lotka-Voterra) e pode ser aplicado para explicar a formação, expansão e retração de diferentes aglomerados urbanos próximos que se dão a partir dos fluxos migratórios que acontecem entre eles (DAVIES et al., 2014).

Assim como o modelo proposto por Wilson (2008) para se tentar compreender a formação de aglomerações urbanas, podem se utilizar ideias e conhecimentos advindos de outras ciências na busca da compreensão dos diversos fenômenos urbanos. As cidades são, muitas vezes, comparadas a organismos pelas suas semelhanças com determinados deles. Exemplo disso é o surgimento do conceito de “metabolismo urbano”, numa analogia com o metabolismo dos seres vivos que, assim como as cidades, necessitam consumir matéria e energia para manutenção de suas atividades vitais e de seu crescimento e que ao mesmo tempo promovem o descarte de produtos inutilizáveis (GIRARDET, 1996).

Um dos fenômenos encontrados em sistemas complexos é a escalabilidade, ou leis de escala. Entender as leis de escala para um determinado sistema significa entender como as propriedades desse sistema se apresentam nas diferentes escalas. No universo da biologia, por exemplo, uma das propriedades estudadas pode ser a taxa metabólica basal dos animais (quantidade de energia demandada por um determinado animal para manter suas atividades vitais no repouso). As taxas metabólicas basais podem ser investigadas em diferentes escalas nos animais, ou seja, para animais com diferentes valores de massa corporal.

Kleiber (1932) mostrou, já em 1932, a relação entre a taxa metabólica basal e a massa corpórea de diferentes espécies de animais. O resultado mostra, diferentemente do que se poderia imaginar, que os animais com maior massa consomem menos energia por unidade de massa do que animais menores. Mais do que isso, para um conjunto bastante diverso de diferentes animais há uma relação bem definida entre a taxa metabólica basal e a massa corporal. Um dos levantamentos dessa relação está apresentado na figura 3.

Figura 3 – Relação entre a taxa metabólica basal e a massa corporal para diversos animais.

Os dados da relação entre taxa metabólica e massa corporal estão apresentados na figura 3 em escala *log-log*, ou seja, ambos os eixos estão em escala logarítmica. Utilizando-se a escala logarítmica para ambos os eixos encontra-se uma reta que se ajusta aos dados, a qual tem uma inclinação bem determinada. A relação entre essas grandezas pode ser expressa da seguinte maneira:

$$\log T_{met} \propto \beta \log M \quad (1)$$

com T_{met} sendo a taxa metabólica basal medida em Watts, M a massa corporal medida em kg e β uma constante.

O fato de β ser uma constante caracteriza esse sistema como invariante em escala. Isto quer dizer que, para o mundo dos animais, é possível prever a taxa metabólica de qualquer animal sabendo apenas a sua massa e vice-versa.

Além da interessante propriedade da invariância de escala para esse conjunto de dados, eles apresentam outra característica bastante interessante. O valor de β é menor do que 1. Mais precisamente, $\beta = 3/4$. Isto significa que há uma economia de escala nos animais maiores, ou pode-se dizer também que há uma relação sublinear na escala *log-log* entre taxa metabólica e massa corporal. Em outras palavras, um animal A com o dobro da massa de uma animal B necessita de 75% da energia por unidade de massa do animal B para manter suas atividades vitais.

Assim como no campo da biologia, as cidades também podem estudadas sob a ótica dos sistemas complexos. Como nas ciências biológicas, as cidades são problemas de complexidade organizada. Elas não apresentam *um* problema de complexidade organizada que, se compreendido, é a explicação de tudo. As variáveis são diversas, mas não desordenadas; elas estão “inter-relacionadas num todo orgânico” (JACOBS, 2011). Enxergar as cidades como sistemas complexos parece ser algo natural, o que é defendido por diversos autores como Batty (2009), Bettencourt (2013) e McPhearson et al. (2016). Essa visão pode contribuir para a identificação de relações fundamentais sobre como as cidades e suas atividades funcionam, de maneira que esse conhecimento possa auxiliar na melhor elaboração e escolha de políticas públicas. As previsões sobre as consequências de determinadas ações podem ser mais assertivas, assim como as trajetórias das cidades, os compromissos que se colocam sobre os ônus e benefícios do crescimento das cidades, os impactos locais, regionais e globais da crescente urbanização no mundo (BAI et al., 2010).

As cidades, ou sistemas urbanos, podem exibir diversas características presentes nos sistemas complexos. Chen e Zhou (2008), por exemplo, descrevem como as ideias de criticalidade auto-organizada (*SOC – Self-organized criticality*) e de leis de escala (ambos conceitos intimamente ligados às teorias dos sistemas complexos) podem ser utilizadas no contexto das cidades. Eles apresentam dados empíricos que caracterizam as cidades e sistemas urbanos como sistemas complexos.

A vida urbana não é previsível como as leis newtonianas. As teorias de sistemas complexos dão suporte justamente para se entenderem os sistemas a partir de uma outra ótica, que não é a da previsibilidade com 100% de acurácia de sua trajetória ou comportamento. Ao invés disso, propõe-se o entendimento de suas características gerais e como elas evoluem ao longo do tempo. A maneira efetiva de se gerenciar as cidades é descobrir seus princípios intrínsecos de auto-organização, e então trabalhar com eles em busca dos percursos desejados (BALL; HELBING, 2012).

As cidades apresentam propriedades emergentes, dinâmicas que estão longe do equilíbrio, e requerem uma enorme quantidade de energia para sua manutenção. Muitos sistemas urbanos apresentam propriedades de sistemas complexos adaptativos, o que significa que eles são altamente interconectados e imprevisíveis enquanto compostos por subsistemas modulares que conferem redundância e são dotados de resiliência. Tratar de complexidade com sistemas urbanos é desafiador e necessita que as teorias urbanas incorporem métodos, ferramentas e abordagens das ciências dos sistemas complexos

adaptativos. Os esforços para se compreender a natureza complexa dos sistemas urbanos são relativamente recentes, mas pesquisas nos sistemas complexos urbanos estão provendo uma base inicial para descrever alguns dos seus padrões fundamentais. O objetivo desse tipo de abordagem é desenvolver de maneira cientificamente rigorosa um entendimento dos sistemas urbanos, nas suas múltiplas escalas, para que seja possível aprimorar os princípios do planejamento urbano, do design de cidades, da gestão e da governança, em busca de cidades e processos de urbanização mais sustentáveis, igualitários e resilientes às mudanças globais (MCPHEARSON et al., 2016).

4.1 As leis de escala aplicadas às cidades

A maneira como as cidades modernas estão estruturadas permite que se façam diversas analogias entre o universo da biologia e a vida urbana. Assim como ocorre em seres vivos complexos (mamíferos, por exemplo), as cidades são compostas pela sobreposição de inúmeras redes (rede de distribuição de energia elétrica, rede viária, rede de abastecimento de água, rede de coleta de esgoto), pela interação entre diversos elementos com funções bastante específicas (empresas, trabalhadores, universidades, órgãos do estado e cidadãos, funcionários da segurança, funcionários da saúde, funcionários da educação), por processos de crescimento ou expansão (crescimento vertical e espraiamento, crescimento populacional), pela presença de diversos tipos de fluxos (fluxo de veículos, de pessoas, de cargas, de lixo, de produtos). Elas são construídas como resultado das relações entre os mais diversos atores (agentes governamentais, indústria da construção civil, classe trabalhadora, empresários) que demandam pelo suprimento de suas necessidades individuais e vitais e que buscam a satisfação de seus interesses. Dadas as semelhanças e analogias entre as cidades e aspectos da natureza dos seres vivos, é natural perguntar-se sobre a possibilidade da utilização de modelos e ideias provenientes de áreas como a Biologia e Ecologia na modelagem das dinâmicas nas cidades.

Considerando-se que as cidades possam ser entendidas como sistemas complexos, abre-se o espaço para aplicação de diversas teorias na tentativa de explicação dos fenômenos urbanos. Os métodos de sistemas complexos podem ter, assim, o potencial para produzir conhecimento que possa subsidiar tomadas de decisões e políticas públicas. Eles podem

contribuir também para se ter um melhor entendimento sobre os efeitos e efetividade de ações sobre as cidades (FURTADO; SAKOWSKI; TÓVOLLI, 2015).

Evidências sugerem que as cidades são sistemas complexos que se desenvolvem, crescem e evoluem. Seu crescimento se dá a partir de um processo *bottom-up*, ou seja, ele pode ser descrito a partir de seu tamanho e suas formas, seguindo leis de escala bem definidas que resultam de um intenso processo de competição por espaço. A integração das teorias urbanas e das teorias de redes, fractais, alometria, entre outras, são o suporte para se tentar descrever as cidades dentro da perspectiva dos sistemas complexos e para a criação de uma ciência das cidades (BATTY, 2008).

É nas cidades onde há intensa interação social, onde há formação de inúmeras redes, onde há um grande número de conexões que crescem e se adensam e que, aumentando o contato e interação entre seus habitantes, produzem os mais diversos efeitos em nível local e global. As transformações do meio urbano e seus impactos se dão pela combinação das ações dos indivíduos (e grupos de indivíduos) e suas interações. Não se trabalha, portanto, com o paradigma de que a cidade é o resultado de ações do tipo *top-down*, onde as decisões que determinam o estado do sistema são tomadas de cima para baixo. Pelo contrário, trabalha-se com a ideia de que o estado do sistema resulta das diversas combinações entre ações individuais e de grupos de indivíduo, propiciadas pela construção de redes, numa lógica de *bottom-up*, ou de baixo para cima. O sistema passa a ser explicado como resultado das interações e tomadas de decisão de suas partes, semelhante ao que ocorre nos organismos (BATTY, 2012).

A ideia de que a cidade pode ser comparada a um organismo não é recente. Em 1965, por exemplo, Wolman (1965) concebeu o conceito de metabolismo urbano. A cidade poderia ser comparada a um organismo vivo, o qual consome recursos do meio onde vive para a manutenção de suas funções vitais e promoção do seu crescimento, produzindo resíduos resultantes dos processos metabólicos.

De maneira análoga, uma cidade necessita de matéria prima para sua manutenção, construção e desenvolvimento, produzindo como resultado do uso desses recursos dejetos, lixo, poluição, etc. Na prática, o estudo do metabolismo urbano seria a quantificação dos *inputs*, *outputs* e armazenamento de energia, água, nutrientes, materiais e dejetos produzidos para uma região urbana (KENNEDY; PINCETL; BUNJE, 2011).

Todas as comparações e analogias feitas entre características presentes no estudo da biologia e das cidades levou Bettencourt et al. (2007) a investigarem a aplicabilidade das leis de escala aos sistemas urbanos.

Apesar da crescente importância das cidades nas sociedades modernas, nossa capacidade de entendê-las cientificamente e transformar esse conhecimento em ações tem sido limitada (BETTENCOURT, 2013). Uma dos complicadores para o entendimento das cidades de maneira ampla é a sua característica multidisciplinar e multifacetada. Numa cidade há questões de infraestrutura, saúde, economia, meio ambiente, sociais, espaciais. Além disso, essas questões se colocam nas mais diversas escalas, desde cidades pequenas até as grandes regiões metropolitanas.

Bettencourt (2013) argumenta que é possível se criar um arcabouço teórico capaz de descrever e explicar as propriedades das cidades, bem como prever como elas evoluem à medida que crescem. A busca por desenvolver uma ciência das cidades, passa pela formulação de teorias e modelos relativamente genéricos que representem as relações intraurbanas, a formação das aglomerações urbanas e suas dinâmicas (BATTY, 2008). Isto torna-se viável atualmente dada a grande quantidade de informações disponíveis. Batty (2012) mostra de forma prática como as cidades podem ser abordadas a partir dos conceitos e teorias dos sistemas complexos.

Leis de escala semelhantes aos apresentados por Kleiber (1932) foram observados também por Bettencourt et al. (2007) para o contexto das cidades. Considerando um conjunto de cidades como um sistema complexo e fazendo uma analogia com o mundo animal, Bettencourt et al. (2007) fizeram o levantamento de diversos indicadores urbanos para cidades de diferentes tamanhos nos Estados Unidos.

A analogia com o mundo animal se dá pela investigação da relação entre esses indicadores urbanos e o tamanho das cidades, onde a taxa metabólica seria análoga a um indicador urbano e a massa corporal análoga ao tamanho da cidade. Os indicadores analisados são grandezas totais para as cidades (como riqueza total produzida, extensão total de vias, extensão total de rede de distribuição de energia elétrica) e o tamanho delas é dado pela sua população. Bettencourt et al. (2007) apresentam dados para diversos indicadores para cidades com mais de 50 mil habitantes. Dois dos indicadores investigados estão apresentados na figura 4.

Diferentemente do que ocorre no mundo animal, para os indicadores das cidades norte americanas apresentados na figura 4 não há economia de escala. Acontece, na verdade,

Figura 4 – Leis de escala em cidades dos Estados Unidos

Fonte: Bettencourt et al. (2007)

justamente o contrário. Com $\beta > 1$ para os dois casos apresentados ($\beta = 1,12$ para os salários e $\beta = 1,15$ para empregos supercriativos) há um comportamento superlinear na escala *log-log*. Em outras palavras, em uma cidade *A* com o dobro do tamanho (dobro da população) de uma cidade *B* os salários *per capita* são 12% maiores do que na cidade *B*. O raciocínio análogo vale para os empregos supercriativos.

A figura 5 mostra uma comparação interessante entre o metabolismo dos animais e o “metabolismo” das cidades. Enquanto o metabolismo animal apresenta característica sublinear, caracterizada por um valor de $\beta > -1$ para a frequência cardíaca dos mamíferos (figura 5a), o “metabolismo” da cidade apresenta característica superlinear, com $\beta > 1$ para a velocidade com que se caminha nas cidades (figura 5b).

Figura 5 – Frequência cardíaca dos animais e o velocidade da caminhada nas cidades

Fonte: Bettencourt et al. (2007)

Buscando verificar a validade e generalidade das leis de escala, (BETTENCOURT; LOBO; WEST, 2008) analisaram dados para diversas cidades de diferentes contextos (cidades de diferentes países, construídas a partir de processos históricos, sociais e culturais

distintos, localizadas em regiões com climas e geografias variadas). Não só houve a identificação de leis de escala como também uma caracterização de indicadores que produzem comportamentos sublineares, lineares e superlineares.

Para alguns conjuntos de dados, ligados principalmente à infraestrutura, o mesmo comportamento de economia de escala encontrado nos seres vivos foi observado. Ou seja, comparando-se cidades de diferentes tamanhos em um determinado sistema urbano (de um determinado país, por exemplo), observa-se que as cidades maiores necessitam de menos infraestrutura per capita para manutenção e crescimento de suas atividades do que as cidades menores.

O efeito contrário à economia de escala, caracterizado por comportamento superlinear, foi encontrado, principalmente, para indicadores associados às interações sociais, como violência, propagação de doenças e produção de conhecimento. A incidência dos casos de AIDS no Brasil e sua relação com o tamanho populacional das cidades é um dos exemplos de comportamento superlinear na escala *log-log* (ANTONIO et al., 2014). Constatou-se que as maiores aglomerações urbanas apresentam maior ocorrência de casos *per capita* do que as menores.

Outro exemplo de crescimento superlinear na escala *log-log* foi o constatado no consumo de energia. A relação constatada é de que quanto maior a cidade, em termos populacionais, maior é o consumo per capita de energia, o que tem implicações importantes para o planejamento futuro de uso de recursos, na eficiência dos equipamentos, nos processos de expansão urbana, etc. (HORTA-BERNÚS; ROSAS-CASALS, 2015).

Essas constatações sobre os padrões de escalamento nas cidades parecem ser relativamente independentes do contexto do país em estudo (BETTENCOURT et al., 2007). Para explicar suas origens, tem-se teorizado a respeito buscando-se descrever os comportamentos encontrados.

As evidências levantadas por (BETTENCOURT et al., 2007) conduzem à formalização do arcabouço teórico para descrição dos resultados encontrados. Algumas propriedades das cidades estariam associadas diretamente ao tamanho delas. Cada aspecto variaria, então, de acordo com o tamanho de cada cidade e eles poderiam ser descritos com leis potência na forma

$$Y(t) = Y_0 N(t)^\beta \quad (2)$$

Nesta equação, $Y(t)$ representa algum indicador associado à vida urbana (por exemplo o número de homicídios, mortalidade infantil, extensão de ruas pavimentadas, salários) no tempo t , $N(t)$ representa o tamanho de uma cidade no tempo t em termos de sua população, Y_0 é uma constante e o valor de β reflete a dinâmica existente entre o indicador em análise e o tamanho da cidade.

Resultados empíricos suportam a tese de que β assume valores específicos dependendo do tipo de indicador estudado. Segundo Bettencourt et al. (2007), o valor de β pode ser separado em três grupos:

- $\beta > 1$ para indicadores relacionados às interações sociais. São os indicadores que existem devido às interações humanas nas suas mais variadas formas. São exemplos: os salários, a proliferação de doenças, taxas de violência, geração de patentes, entre outros;
- $\beta < 1$ para indicadores relacionados à infraestrutura. São os indicadores que caracterizam as infraestruturas de um ambiente urbano. São exemplos: extensão de vias pavimentadas, extensão das redes (de fornecimento de energia, de água, de esgoto);
- $\beta = 1$ para indicadores relacionados às necessidades individuais. São os indicadores que representam as necessidades individuais. São exemplos: número de habitações, número de empregos, consumo de alimentos, consumo de energia.

Uma das maneiras de se estimar o valor de β a partir da equação 2, utilizando os dados levantados, é a seguinte:

1. aplica-se o logaritmo à equação 2, obtendo-se a equação

$$\log(Y(t)) = \log(Y_0) + \beta \cdot \log(N(t)) \quad (3)$$

2. aplica-se uma regressão linear na equação 3 utilizando o método dos mínimos quadrados.

Bettencourt et al. (2010) apresentam o crescimento superlinear (na escala logarítmica) da riqueza produzida em áreas metropolitanas nos EUA em relação à sua população. Para esta análise foram levantados dois grupos de dados:

- um conjunto de dados com as populações das regiões estatísticas metropolitanas, as *MAS – Metropolitan Statistical Area*. Elas são definidas pelo *U.S. Office of Management and Budget* como regiões tendo pelo menos uma área urbanizada com

mais de 50 mil pessoas, mais os territórios adjacentes com alto grau de integração social e econômica com a centralidade;

- um conjunto de dados sobre a riqueza produzida numa área metropolitana, representado pelo produto metropolitano, *GMP – Gross Metropolitan Product*. Ele é definido pelo *U.S. Department of Commerce Bureau of Economic Analysis*, e é a medida do valor de mercado de bens e serviços dentro de uma área metropolitana num determinado período.

Os resultados mostram um crescimento superlinear na escala logarítmica para o *GMP*, com $\beta = 1,126$. β apresenta invariância de escala, ou seja, não importa a escala em que a cidade é observada (tamanho da cidade), o valor de β para um determinado indicador analisado é constante.

Bettencourt, Lobo e Strumsky (2007) apresentam o crescimento superlinear na escala logarítmica para indicadores de criatividade (patentes, empregos na área de criação, invenções). A característica superlinear encontrada para este conjunto de indicadores pode ser atribuída à maior quantidade *per capita* de pessoas trabalhando em áreas criativas nas grandes cidades e também ao maior contato que elas têm entre si, graças às inúmeras redes que as conectam e que são características dos grandes centros urbanos.

Kühnert, Helbing e West (2006) descrevem as leis de escala para indicadores associados a redes de fornecimento, para alguns países europeus. Foi utilizado um grupo de indicadores bastante variado, que incluiu a energia elétrica, postos de gasolina, vendedores de carros, hospitais, leitos hospitalares, postos de correio, farmácias, médicos e restaurantes. Apesar desta variedade de indicadores e dos diferentes países analisados, chegou-se às seguintes conclusões :

- os expoentes de escala (β) foram consistentes comparando-se os diferentes países;
- o expoente igual a 1 foi encontrado apenas para alguns sistemas de fornecimento;
- foram encontradas características superlineares e sublineares para alguns indicadores.

Para os dados levantados, o número de farmácias, postos do correio e médicos apresentou um crescimento linear. Esta proporcionalidade estaria, segundo Bettencourt et al. (2007), associada às demandas individuais, combinadas às suas características de acessibilidade para a população. Além disso, algumas dessas atividades são reguladas pelos governos. Isso tudo faz com que haja um número aproximadamente proporcional desses locais que suprem as necessidades individuais.

O número de postos de gasolina e vendedores de carro apresentou característica sublinear, indicando economia de escala. Esse resultado é razoável, visto que em áreas mais densamente povoadas como as grandes cidades, há um uso mais eficiente no que concerne as redes de suprimento de materiais.

Por fim, o número de restaurantes apresentou característica superlinear. Esse tipo de indicador estaria relacionado à satisfação das necessidades sociais e de comunicação das pessoas e é tão mais intenso quanto maior a cidade.

As redes que conectam as pessoas (infraestruturas de mobilidade e de comunicação) crescem com o crescimento das cidades. A conectividade das pessoas aumenta e é esse aumento que potencialmente produz os efeitos de crescimento superlinear alguns indicadores urbanos. O crescimento superlinear da propagação de doenças (ANTONIO et al., 2014) e do volume de contatos telefônicos (SCHLÄPFER et al., 2014) são exemplos desse aumento de conectividade.

As relações sociais parecem ser um ponto chave no entendimento do funcionamento global das cidades. Elas se dão não apenas pelo encontro direto entre as pessoas, possibilitado pelas infraestruturas construídas, mas também pelo fluxo de informações entre as pessoas, possibilitado por outros tipos de infraestrutura. A intensidade das relações sociais será tão maior quanto maior a densidade populacional de uma determinada área. Para Pan et al. (2013), a densidade populacional seria um parâmetro mais preciso para se entender os fenômenos urbanos do que simplesmente a população.

Análises de Arcaute et al. (2015) mostram que o tamanho populacional sozinho não provê informações suficientes para descrever ou prever o estado de uma cidade, indicando que as leis de escala propostas não podem ser corroboradas. Uma abordagem mais aprofundada sobre a definição de cidade é proposta, considerando-se duas definições alternativas ao tamanho de uma cidade como sendo seu número de habitantes: uma abordagem que leva em consideração a densidade populacional das aglomerações urbanas e outra que, além da densidade populacional, considera também os efeitos metropolitanos (os efeitos de atração que as maiores cidades exercem sobre as cidades menores).

Levinson (2012) faz uma avaliação específica para a questão das redes de transporte viário para as 50 maiores áreas metropolitanas dos EUA. As redes maiores presentes nas maiores cidades apresentam maior conectividade, ou seja, os nós pertencentes às maiores redes são mais acessíveis por outros nós. Em outras palavras, as pessoas têm maior facilidade para acessar os locais e, principalmente, outras pessoas. Outra característica

encontrada com o crescimento das redes de transporte viário é o crescimento sublinear da extensão de vias *per capita* (economia de escala na extensão viária). Uma das explicações para esse fenômeno é a de que, dentro de um espaço com grande adensamento populacional, é mais viável se construir infraestruturas residenciais e de serviços verticalmente do que construir infraestruturas de transporte horizontalmente. Além disso, aumentar os kms de vias construídas impacta direta e negativamente nos tempos de viagens.

Os resultados utilizando essas outras definições de cidade mostraram que houve apenas pequenas variações de β em torno de 1, variações essas que não se mostraram relevantes. Para a maioria dos indicadores houve crescimento linear na escala logarítmica com o tamanho da cidade, independentemente da definição das fronteiras urbanas. Isso contraria os resultados encontrados por Bettencourt et al. (2007). Para alguns indicadores, os valores de β foram inclusive na direção contrária aos descritos por Bettencourt et al. (2007) (ao invés de $\beta > 1$, $\beta < 1$).

Outra interessante abordagem sobre os efeitos da escala urbana foi proposta por Kennedy et al. (2015). Comparando os fluxos de matéria e energia nas megacidades no mundo (cidades com mais de 10 milhões de habitantes), observa-se também consistência nas leis de escala para diferentes indicadores, apesar das cidades se apresentarem em contextos bastante diversos. Dentro deste grupo de cidades, foi identificado o comportamento superlinear do PIB e da produção de lixo. Em relação ao consumo de energias, para o consumo total de energia elétrica foi encontrado comportamento superlinear, assim como o encontrado em Bettencourt et al. (2007). Contudo, contrariamente aos achados Bettencourt et al. (2007), que encontraram um comportamento sublinear para o consumo de gasolina, Kennedy et al. (2015) detectaram crescimento superlinear para este indicador.

Numa análise do nível de emissões de CO_2 para as cidades norte americanas, apresentada por Fragkias et al. (2013), observou-se que há uma relação praticamente linear em escala logarítmica para as emissões desse tipo de gás. Esse resultado vai contra a ideia de que as cidades maiores seriam mais eficientes, pelo menos em relação a este aspecto em particular.

Em contrapartida, Lamsal et al. (2013) encontraram uma relação sublinear na escala logarítmica para as emissões de NO_2 nos EUA, Europa, China e Índia. Embora a taxa de crescimento em escala logarítmica tenha sido diferente para cada um desses territórios, todos apresentam crescimento sublinear, com β variando entre 0,36 – 0,66.

Avaliando o crescimento das áreas urbanas nos EUA conjuntamente com o crescimento populacional de 1950 a 2000, Marshall (2007) encontra uma relação de escala entre população e densidade populacional. A área urbana escala proporcionalmente ao crescimento populacional elevado a uma constante. Matematicamente, essa relação se traduz da seguinte maneira:

$$A \propto P^n \quad (4)$$

onde A é a área, P é o tamanho da população e n é uma constante. Esta relação é idêntica à apresentada na equação 2.

Muitas análises sobre as leis de escala e propriedades das cidades geralmente são feitas a partir de indicadores que agregam as quantidades, como, por exemplo, a riqueza total produzida numa cidade e a taxa de mortalidade infantil total. Essa agregação mascara aspectos que aparecem em escalas menores nas cidades, em níveis de desagregação maiores. As desigualdades espaciais e de renda são aspectos apenas capturados em escalas intraurbanas. Isto não significa que a abordagem mais geral não seja relevante, porém há de se ter ciência que ela desconsidera as variações que são observáveis apenas em escalas menores. Isto é particularmente verdade para a realidade brasileira, em que diversos tipos de desigualdades são bastante acentuadas.

Tendo em vista essas questões, Sarkar (2018) propõe a aplicação da análise das leis de escala para indicadores de desigualdade para territórios da Austrália e EUA. Sarkar (2018) mostra como as distribuições geográficas, desigualdades de renda no espaço e o custo de moradia variam em relação ao tamanho populacional das cidades. A população de alta renda apresenta crescimento superlinear na escala logarítmica em relação à população total, enquanto a população de renda baixa apresenta crescimento sublinear. O mesmo vale para os custos de moradia, ou seja, as cidades maiores apresentam maiores concentrações moradias de alto custo do que as cidades menores.

Uma abordagem semelhante é feita por Oliveira, Bastos-Filho e Menezes (2017) sobre a criminalidade nos EUA e Reino Unido. A criminalidade, assim como a riqueza e preços de moradia, se manifesta com intensidades diferentes no espaço. Além disso, criminalidade é um termo bastante geral que agrega inúmeras formas de crimes. Oliveira, Bastos-Filho e Menezes (2017) mostram como a concentração de diferentes tipos de crimes é independente do tamanho das cidades, em termos de suas populações, embora o número

total de crimes apresente dependência em relação ao tamanho das cidades. Neste estudo foram apresentados dados para a concentração de crimes de furto, roubo e assalto e não foi encontrada nenhuma dependência desses indicadores em relação à população.

Os fenômenos ligados à política também podem apresentar interessantes leis de escala. O perfil dos eleitores varia de região para região e pode, muitas vezes, apresentar padrões bem definidos. Bokányi, Szállási e Vattay (2018) abordam essa questão para as eleições presidenciais dos EUA entre 1948 e 2016 e para o referendo sobre a saída do Reino Unido da União Europeia em 2016. As diferenças de perfil dos eleitores entre as zonas rurais e urbanas é explicada a partir da perspectiva das leis de escala urbana.

Para as eleições presidenciais de 2016 nos EUA, os votos no partido democrata escalam de maneira superlinear na escala logarítmica em relação ao tamanho das cidades, enquanto os votos no partido republicano escalam de maneira sublinear. Situação análoga foi observada para o referendo realizado em 2016 sobre a saída do Reino Unido da União Europeia. Neste caso, os votos para a permanência do Reino Unido na União Europeia escalam de maneira superlinear na escala logarítmica em relação à população, enquanto os votos para a saída escalam de maneira sublinear.

As variações dos impactos espaciais da urbanização também podem ser observadas relativamente às diferentes escalas. A questão das águas em cidades dos EUA abordada por Steele (2017) é um exemplo desta abordagem. Três indicadores foram analisados em relação à população: a extensão de águas, área de águas e extensão de águas impróprias para o consumo. Steele (2017) avalia as leis de escala para esses três indicadores. Contudo, diferentemente de outras análises, os valores de β foram calculados para diferentes recortes de população. Para a extensão de águas foram consideradas três faixas de população:

- Até 30 mil habitantes. Para esta faixa foi calculado um $\beta = 1,02$
- De 30 mil habitantes a 1 milhão de habitantes Para esta faixa foi calculado um $\beta = 0,95$
- Mais de 1 milhão de habitantes. Para esta faixa foi calculado um $\beta = 0,67$

Para a área de águas foram utilizadas duas faixas de população:

- Até 400 mil habitantes. Para esta faixa foi calculado um $\beta = 1,18$
- Mais de 400 mil habitantes. Para esta faixa foi calculado um $\beta = 0,81$

E para as águas impróprias foram utilizadas também duas faixas de população:

- Até 25 mil habitantes. Para esta faixa foi calculado um $\beta = 0,61$
- Mais de 25 mil habitantes. Para esta faixa foi calculado um $\beta = 0,98$

A subdivisão da população em algumas determinadas faixas fez com que β assumisse valores consideravelmente diferentes, fazendo com que um mesmo indicador apresentasse crescimento sublinear e superlinear na escala logarítmica dependendo da faixa de população considerada.

Cebrat e Sobczyński (2016) realizaram o estudo dos efeitos das leis de escala urbana considerando a quase totalidade das cidades polonesas e indicadores como o consumo de eletricidade, número de empresas e PIB. Além de avaliar as leis de escala para a totalidade das cidades pesquisadas, foram feitas análises análogas para diferentes grupos de cidades. As cidades foram separadas em grupos de acordo com a afinidade entre elas, considerando-se diversos indicadores (número de empresas *per capita*, número de empresas por m^2 , consumo de energia nas casas por área total ocupada por moradias, entre outros). Verificou-se que as leis de escala globais, quando se considera a totalidade das cidades da amostra, foram diferentes das leis de escala para os diversos grupos. Para o PIB, por exemplo, foi encontrado crescimento superlinear na escala logarítmica em relação à população com $\beta = 1,327$, para o ano de 2002 e para a totalidade das cidades da amostra. Quando as cidades foram separadas em diferentes grupos, valores diferentes de β foram encontrados para cada grupo. No caso do PIB, para um determinado grupo foi encontrado $\beta = 1,308$ e, para outro, $\beta = 1,072$.

Diferentemente do que se poderia pensar, o volume de *tweets* da rede social Twitter não escala de maneira superlinear com a população. Uma vez que que nas cidades maiores há maior intensidade de interação entre as pessoas, poderia se supor o comportamento superlinear para este indicador. Paradoxalmente, quando se olha para o comportamento dos indivíduos, a velocidade com que os *tweets* são enviados é maior em áreas mais densamente povoadas. Esta aparente contradição pode ser explicada pelo fato de haver um certo número de indivíduos muito ativo nesta rede social nas grandes cidades, que seriam como as grandes fontes propagadoras de informação. As cidades menores teriam distribuição mais homogênea de *tweets* entre os indivíduos pertencentes à rede (GROSS; MURTHY; VARSHNEY, 2017).

Tendo em vista investigar os padrões e características do crescimento das taxas de homicídio no Brasil, Alves, Ribeiro e Mendes (2013) apresentam, como parte dessa

investigação, dados sobre o número de homicídios em 1980 para 528 municípios. Segundo os dados levantados, para essa amostra de municípios foi identificado um crescimento superlinear na escala logarítmica dos homicídios em relação à população, com $\beta = 1,15$. Este levantamento tem concordância com a ideia de que cidades maiores apresentam taxas de criminalidade mais elevadas.

4.2 *As leis de escala para as cidades brasileiras*

Embora haja uma certa tendência na literatura na direção de confirmar os relações descritas por Bettencourt et al. (2007), há muitas questões em aberto ainda. Dentre as principais conclusões e considerações apresentadas por Bettencourt et al. (2007), têm maior relevância para esta pesquisa as seguintes:

- As leis de escala para sistemas urbanos são gerais. Eles devem valer para qualquer sistema urbano, independente do contexto sendo analisado
- Os indicadores são comparados ao tamanho das cidades, que é dado pela sua população (número de habitantes)
- Os indicadores de infraestrutura apresentam característica sublinear
- Os indicadores sociais apresentam característica superlinear
- Os indicadores relativos às necessidades individuais apresentam característica linear

Não há, entretanto, consenso em relação a essas afirmações. As análises aqui apresentadas buscam verificar a validade e generalidade de todas essas afirmações, a partir da investigação das leis de escala especificamente para o contexto das cidades brasileiras.

Em primeiro lugar foi feita a escolha das cidades brasileiras a serem analisadas. Uma vez que os Censos do IBGE dispõem de uma grande quantidade de dados, tomou-se como base as planilhas com dados dos Censos dos anos de 1991, 2000 e 2010. Os dados utilizados dos Censos associam, entretanto, os indicadores aos municípios (áreas administrativas não necessariamente urbanas) e não a cidades (áreas predominantemente urbanas, com maiores densidades populacionais). Veiga (2002) propõe uma metodologia para caracterizar as áreas rurais e urbanas. De maneira simplificada, segundo Veiga (2002), os municípios poderiam ser classificados como:

- Rurais: municípios de pequeno porte que possuem até 50 mil habitantes e menos de 80 hab/km^2

- De médio porte: municípios que registram uma população no intervalo de mais de 50 a 100 mil habitantes, ou cuja densidade supere os 80 *hab/km²*, mesmo que tenham menos de 50 mil habitantes
- Centros urbanos: os municípios com mais de 100 mil habitantes

Tendo em vista esta classificação, foram feitas análises para:

- os 14 indicadores selecionados (seção 4.3);
- os Censos de 1991, 2000 e 2010;
- diferentes faixas de população, a fim de se entender a validade da utilização da população municipal como grandeza adequada para descrever leis de escala (capítulo 5).

Para todos os indicadores e períodos censitários foram produzidos gráficos e calculados os valores de R^2 e β , considerando amostras contendo municípios com mais de 50 mil habitantes.

Além disso, foram produzidos gráficos e calculados os valores de R^2 e β considerando-se outras amostras de municípios, variando-se a população mínima considerada entre 0 (zero) habitantes e 2,49 milhões, com intervalos a cada 10 mil habitantes. Em outras palavras, foram produzidos gráficos de *indicador vs população* considerando-se: a totalidade dos municípios das amostras, municípios com mais de 10mil habitantes, municípios com mais de 20 mil habitantes, municípios com mais de 30 mil habitantes e assim por diante, até amostras considerando-se apenas municípios com mais de 2,49 milhões de habitantes. O limite de 2,49 milhões de habitantes como população mínima se deve ao fato de haver apenas dois municípios nos Censos de 1991 e 2000 e apenas quatro municípios no Censo de 2010 com população maior que este número, não fazendo sentido, portanto, a análise para conjuntos de municípios com populações maiores que essa.

Além dos gráficos *indicador vs população* foram produzidos também gráficos com os valores calculados de β e R^2 *versus* a população mínima considerada para cada um dos indicadores. Os algoritmos implementados na linguagem de programação *Python* (ver seção 4.4) permitiram a produção automatizada de uma grande quantidade de gráficos e valores calculados. No total foram gerados 10.658 gráficos, dos quais apenas uma minoria é apresentada aqui.

Para se visualizar as diferenças nos resultados obtidos considerando-se diferentes valores de população mínima, serão apresentados apenas três conjuntos de gráficos, para diferentes faixas de população:

- com 0 (zero) habitantes como população mínima
- com 50mil habitantes como população mínima
- com 100mil habitantes como população mínima

4.3 Indicadores utilizados

Para a escolha dos indicadores a serem utilizados no estudo das leis de escala para as cidades do Brasil, foram consideradas principalmente as seguintes condições:

1. Indicadores sugeridos na Norma NBR ISO 37120:2017
2. Disponibilidade de dados para as cidades brasileiras com a maior abrangência possível (maior número de cidades possível)

A Norma ABNT NBR ISO 37120:2017 estabelece e define a metodologia para aquisição de uma série de indicadores de qualidade de vida e serviços urbanos. Ela tem por objetivo padronizar a aquisição desses indicadores para que se possa medir a gestão e desempenho das cidades, para que essas medidas sejam comparáveis entre as cidades e, principalmente, para que as melhores práticas sejam compartilhadas. A Norma propõe a utilização de indicadores nas mais diversas áreas, de modo que se possa ter uma visão dos mais diversos aspectos e características das cidades. A avaliação dos indicadores deve sempre ser buscada visando a sustentabilidade, no seu sentido mais amplo. As cidades devem ser resilientes, dotadas de boa gestão e serem sustentáveis econômica, social e ambientalmente (ABNT, 2017).

A grande abrangência dos dados como uma das condições para escolha dos indicadores se deve principalmente ao fato de que quanto maior o número de cidades analisadas no conjunto, maiores as informações sobre as leis da escala urbana no Brasil como um todo. Um conjunto restrito de dados pode gerar resultados que não representem a realidade geral das cidades brasileiras. Além disso, se se pensa em construir uma ciência das cidades, é fundamental que haja informações sobre o maior número de aglomerações urbanas possível, a fim de que conclusões relevantes possam ser tiradas.

Tabela 1 – Indicadores utilizados do Censo e os indicadores correspondentes presentes na Norma NBR ISO 37120:2017

Indicador do Censo	Indicador da Norma NBR ISO 37120:2017
Taxa de desocupação - 18 anos ou mais	Taxa de desemprego da cidade
Taxa de desocupação - 18 a 24 anos	Taxa de desemprego de jovens
% de extremamente pobres	% da população abaixo da linha de pobreza
% de 18 anos ou mais com fundamental completo	% de estudantes com ensino primário completo
% de 25 anos ou mais com médio completo	% de estudantes com ensino secundário completo
% de 6 a 17 anos na escola	% de população em idade escolar matriculada em escolas
% de 25 anos ou mais com superior completo	Número de indivíduos com ensino superior completo por 100 000 habitantes
% da população em domicílios com energia elétrica	% de habitantes da cidade com fornecimento regular de energia elétrica
Esperança de vida ao nascer	Expectativa média de vida
Mortalidade até 5 anos de idade	Taxa de mortalidade de crianças menores de cinco anos a cada 1000 nascidos vivos
% de pessoas em domicílios com paredes inadequadas	% da população urbana morando em favelas
% da população em domicílios com coleta de lixo	% da população urbana com coleta regular de lixo (domiciliar)
% de pessoas em domicílios com abastecimento de água e esgotamento sanitário inadequados	% da população da cidade atendida por sistemas de coleta e afastamento de esgoto
% da população em domicílios com água encanada	% da população da cidade com serviço de abastecimento de água potável

A tabela 4 no anexo B contém todos os indicadores da Norma ABNT NBR ISO 37120:2017.

A partir dessa lista de indicadores, foi feita uma busca dos dados disponíveis. Foi feita a escolha por indicadores contidos nos Censos nacionais do IBGE que tivessem relação com indicadores da Norma. A opção por bases de dados do IBGE se deveu principalmente pelo fato da coleta de dados ser padronizada para todas as cidades, de haver dados para três períodos de tempo diferentes (1991, 2000 e 2010) e de haver dados para todas as cidades brasileiras.

Na tabela 1 está apresentada a escolha dos indicadores dos Censos e sua correspondência com os indicadores da Norma ABNT NBR ISO 37120:2017.

A definição dos indicadores do Censo se encontra na tabela 5, no anexo C.

Nesta pesquisa foram utilizadas quantidades absolutas no lugar de porcentagens. Por isso e também para simplificação na apresentação dos resultados, foi feita a mudança

Tabela 2 – Indicadores utilizados do Censo e os correspondentes nomes utilizados

Indicador do Censo	Nome utilizado
Taxa de desocupação - 18 anos ou mais	Desempregados
Taxa de desocupação - 18 a 24 anos	Jovens desempregados
% de extremamente pobres	Pessoas extremamente pobres
% de 18 anos ou mais com fundamental completo	Pessoas com ensino fundamental
% de 25 anos ou mais com médio completo	Pessoas com ensino médio
% de 6 a 17 anos na escola	Crianças e jovens na escola
% de 25 anos ou mais com superior completo	Pessoas com ensino superior
% da população em domicílios com energia elétrica	Pessoas com abastecimento de energia
Esperança de vida ao nascer	Anos vividos
Mortalidade até 5 anos de idade	Mortes até 5 anos de idade
% de pessoas em domicílios com paredes inadequadas	Pessoas em moradia precária
% da população em domicílios com coleta de lixo	Pessoas com acesso à coleta de lixo
% de pessoas em domicílios com abastecimento de água e esgotamento sanitário inadequados	Pessoas com acesso a saneamento básico
% da população em domicílios com água encanada	Pessoas com acesso à água encanada

de nomenclatura dos indicadores dos Censos do IBGE utilizados. A nomenclatura aqui utilizada está apresentada na tabela 2.

4.4 Tratamento dos dados e produção de gráficos e tabelas

Foram agregados numa única planilha em *Excel* dados dos Censos do IBGE de 1991, 2000 e 2010, resultando numa planilha com 237 colunas (sendo 232 delas indicadores) e 16.696 linhas (em torno de um terço das linhas para o ano de 1991, um terço para o ano de 2000 e um terço para o ano de 2010), totalizando 3.656.442 de células.

Para se trabalhar com esta grande quantidade de dados, foi desenvolvido um programa utilizando-se a linguagem de programação *Python*. A escolha desta linguagem de programação se deveu principalmente aos conhecimentos prévios sobre suas potencialidades e à sua flexibilidade para trabalho com planilhas de dados, modelos matemáticos, produção de gráficos, etc.

O objetivo com o programa é extrair os dados da planilha para que sejam calculados os valores de β e R^2 e para que sejam produzidos gráficos semelhantes aos da figura 4 para os indicadores selecionados. Uma vez que apenas catorze indicadores foram selecionados para a análise, os dados contidos na planilha não foram integralmente utilizados. Todavia o programa para manipulação dos dados foi desenvolvido levando em consideração a totalidade dos dados disponíveis, ou seja, com simples adaptações outros indicadores da planilha podem ser analisados. As análises são possíveis também para indicadores que forem adicionados à planilha.

Para praticidade no processamento dos dados, nos casos em que não havia disponibilidade de dados para um determinado indicador, a matriz de dados foi preenchida com zeros. Isto ocorreu para os seguintes casos:

- *peças em domicílios com paredes inadequadas*, para os Censos de 1991 e 2000;
- *desempregados*, para o Censo de 1991;
- *desempregados entre 18 e 24 anos*, para o Censo de 1991;

Para maior clareza e simplicidade, o programa escrito *Python* foi estruturado em diferentes arquivos. São eles::

- **dictionary.py**
- **data_conversion.py**
- **parameters.py**
- **read_plot_data.py**

Nas seções a seguir cada um desses arquivos é descrito com maiores detalhes.

4.4.1 dictionary.py

Este arquivo contém diversas listas. Também é neste arquivo em que é feita a atribuição de números para cada para cada indicador presente na planilha de dados. Foram criadas as seguintes listas:

- uma lista contendo os nomes abreviados dos indicadores da planilha de dados
- uma lista contendo os nomes dos indicadores utilizados na análise
- uma lista para cada unidade federativa do Brasil contendo o código do IBGE dos municípios da unidade federativa correspondente

- uma lista para cada região metropolitana contendo o código do IBGE dos municípios da região correspondente (foram criadas listas apenas para as maiores regiões metropolitanas)
- uma lista contendo o código do IBGE dos municípios de cada capital brasileira

As listas contendo os nomes dos indicadores (tanto os abreviados quanto os utilizados na análise) são utilizadas para o tratamento dos dados e para a identificação dos gráficos produzidos. As listas contendo as capitais, unidades da federação e regiões metropolitanas são utilizadas para identificar essas áreas nos gráficos.

Os números atribuídos a cada indicador servem como índices para identificar a coluna contendo os dados deste indicador na matriz de dados.

4.4.2 data_conversion.py

Em todas as análises feitas nesta pesquisa foram utilizados indicadores com quantidades totais, os quais são comparados com a população total de cada cidade. Entretanto, muitos dados são fornecidos não como quantidades totais. Eles estão disponíveis, por exemplo, na forma de porcentagens da população, como quantidade *per capita* de algum parâmetro, entre outras formas. Assim, os dados que não estão disponíveis como quantidades totais foram convertidos para se obter o indicador em valor absoluto.

No arquivo **data_conversion.py** é feita justamente esta conversão para todos os indicadores da planilha de dados e para todas as cidades. A seguir um exemplo de como foi feita esta conversão.

Conversão do indicador *% de 25 anos ou mais com superior completo* em *número de pessoas de 25 anos ou mais com superior completo*:

$$SUPER25M = \frac{T_SUPER25M}{100} PESO25, \quad (5)$$

onde $SUPER25M$ é o número de pessoas de 25 anos ou mais com superior completo, $T_SUPER25M$ é a porcentagem de pessoas de 25 anos ou mais com ensino superior e $PESO25$ é o número total de pessoas de 25 anos.

4.4.3 parameters.py

Este arquivo foi criado com o intuito de se definir os parâmetros para geração dos gráficos. É onde se define quais serão os indicadores para tratamento de dados e também o valor de parâmetros que modificam a visualização dos dados.

Para se determinar quais indicadores estarão sujeitos à análise, seleciona-se no código os indicadores de interesse. Para modificar a visualização de dados, pode-se ajustar parâmetros que dão destaque na visualização:

- às cidades de acordo com a região do país (figura 6)
- às cidades de alguma região metropolitana escolhida (figura 7)
- às capitais de cada estado (figura 8)
- às cidades de um determinado estado (figura 9)

Figura 6 – Identificação das cidades de acordo com as regiões a que pertencem

Fonte: Censo 2010 do IBGE

Figura 7 – Identificação das cidades pertencentes à Região Metropolitana de São Paulo

Figura 8 – Identificação das capitais de cada estado

Figura 9 – Identificação das cidades pertencentes ao estado de São Paulo

4.4.4 read_plot_data.py

Este é o arquivo principal. É onde os dados da planilha em *Excel* são carregados, lidos e manipulados para se produzirem outros dados e os gráficos. A sequência de procedimentos realizados segue, de maneira simplificada, o fluxo apresentado na figura 10.

Figura 10 – Sequência de operações realizadas no programa

Este trecho do código encontra-se no apêndice A.

5 Resultados

A seguir estão apresentados os resultados mais relevantes, que são os gráficos de cada indicador *versus* a população dos municípios (seção 5.1). Na sequência (seção 5.2) estão apresentados os gráficos da variação de β e R^2 de acordo com a população mínima considerada. Todos os resultados foram gerados com o programa desenvolvido em *Python*.

5.1 Resultados para os indicadores *x* população, para o Censos de 1991, 2000 e 2010

Estão apresentados aqui apenas os gráficos dos indicadores *versus* a população para municípios com mais de 50 mil habitantes. São apresentados conjuntos de gráficos para os Censos de 1991, 2000 e 2010, para os seguintes indicadores:

- Figura 11: Pessoas com acesso a saneamento básico
- Figura 12: Anos vividos
- Figura 13: Mortes até 5 anos de idade
- Figura 14: Pessoas em moradia precária
- Figura 15: Pessoas extremamente pobres
- Figura 16: Pessoas com acesso à água encanada
- Figura 17: Desempregados
- Figura 18: Jovens desempregados
- Figura 19: Crianças e jovens na escola
- Figura 20: Pessoas com ensino fundamental
- Figura 21: Pessoas com acesso à coleta de lixo
- Figura 22: Pessoas com abastecimento de energia
- Figura 23: Pessoas com ensino médio
- Figura 24: Pessoas com ensino superior

A tabela 3 apresenta os valores calculados de β e R^2 para os indicadores utilizados, para os Censos de 1991, 2000 e 2010, para os municípios brasileiros com mais de 50 mil habitantes. Para cada indicador e ano censitário foi feito o ajuste da reta aos dados, considerando-se apenas os municípios com mais de 50 mil habitantes, e calculados β e R^2 . Cada um desses resultados está apresentado também na forma de gráficos nas figuras 11 a 24.

Tabela 3 – Valores calculados de β e R^2 para os indicadores utilizados, para os Censos de 1991, 2000 e 2010, para os municípios brasileiros com mais de 50 mil habitantes

Indicador	1991		2000		2010	
	β	R^2	β	R^2	β	R^2
Pessoas com acesso a saneamento básico	0,67	0,07	0,55	0,07	0,51	0,03
Anos vividos	1,01	0,99	1,01	1,00	1,01	1,00
Mortes até 5 anos de idade	0,78	0,49	0,81	0,59	0,83	0,74
Pessoas em moradia precária	-	-	-	-	0,67	0,10
Pessoas extremamente pobres	0,55	0,14	0,62	0,19	0,54	0,11
Pessoas com acesso à água encanada	1,14	0,85	1,12	0,87	1,05	0,98
Desempregados	-	-	1,15	0,91	1,09	0,86
Jovens desempregados	-	-	1,15	0,90	1,11	0,86
Crianças e jovens na escola	1,01	0,98	0,97	0,98	0,95	0,97
Pessoas com ensino fundamental	1,29	0,88	1,24	0,89	1,18	0,93
Pessoas com acesso à coleta de lixo	1,10	0,83	1,07	0,73	1,02	0,99
Pessoas com abastecimento de energia	1,07	0,96	1,04	0,98	1,01	1,00
Pessoas com ensino médio	1,33	0,83	1,31	0,84	1,27	0,88
Pessoas com ensino superior	1,46	0,63	1,46	0,63	1,36	0,76

5.2 *Variação de β e R^2 para cada indicador segundo a população mínima considerada, para os Censos de 1991, 2000 e 2010*

Além da análise com respeito às características das leis de escala para os municípios com mais de 50 mil habitantes, apresentada na seção anterior, considerou-se também a análise dos valores de β e R^2 para diferentes valores de população mínima. Esses resultados estão apresentados na forma de gráficos nas figuras 25 a 38 e mostram como os valores de β e R^2 variam quando se consideram diferentes valores mínimos da população municipal para o recorte da amostra. Em outras palavras, foram tomadas amostras com todos os municípios, com municípios com mais de 10 mil habitantes, com municípios com mais de 20 mil habitantes e assim por diante e, para cada indicador e ano censitário foi ajustada uma reta aos dados e calculados β e R^2 .

São apresentados conjuntos de gráficos para os Censos de 1991, 2000 e 2010, para os seguintes indicadores:

- Figura 25: Pessoas com acesso a saneamento básico
- Figura 26: Anos vividos
- Figura 27: Mortes até 5 anos de idade
- Figura 28: Pessoas em moradia precária
- Figura 29: Pessoas extremamente pobres

- Figura 30: Pessoas com acesso à água encanada
- Figura 31: Desempregados
- Figura 32: Jovens desempregados
- Figura 33: Crianças e jovens na escola
- Figura 34: Pessoas com ensino fundamental
- Figura 35: Pessoas com acesso à coleta de lixo
- Figura 36: Pessoas com abastecimento de energia
- Figura 37: Pessoas com ensino médio
- Figura 38: Pessoas com ensino superior

Figura 11 – Indicador: Pessoas com acesso a saneamento básico

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 12 – Indicador: Anos vividos

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 13 – Indicador: Mortes até 5 anos de idade

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 14 – Indicador: Pessoas em moradia precária

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 15 – Indicador: Pessoas extremamente pobres

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 16 – Indicador: Pessoas com acesso à água encanada

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 17 – Indicador: Desempregados

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 18 – Indicador: Jovens desempregados

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 19 – Indicador: Crianças e jovens na escola

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 20 – Indicador: Pessoas com ensino fundamental

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 21 – Indicador: Pessoas com acesso à coleta de lixo

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 22 – Indicador: Pessoas com abastecimento de energia

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 23 – Indicador: Pessoas com ensino médio

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 24 – Indicador: Pessoas com ensino superior

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 25 – Variação de β e R^2 para o indicador *Pessoas com acesso a saneamento básico*

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 26 – Variação de β e R^2 para o indicador *Anos vividos*

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 27 – Variação de β e R^2 para o indicador *Mortes até 5 anos de idade*

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 28 – Variação de β e R^2 para o indicador *Pessoas em moradia precária*

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 29 – Variação de β e R^2 para o indicador *Pessoas extremamente pobres*

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 30 – Variação de β e R^2 para o indicador *Pessoas com acesso à água encanada*

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 31 – Variação de β e R^2 para o indicador *Desempregados*

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 32 – Variação de β e R^2 para o indicador *Jovens desempregados*

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 33 – Variação de β e R^2 para o indicador *Crianças e jovens na escola*

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 34 – Variação de β e R^2 para o indicador *Pessoas com ensino fundamental*

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 35 – Variação de β e R^2 para o indicador *Pessoas com acesso à coleta de lixo*

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 36 – Variação de β e R^2 para o indicador *Pessoas com abastecimento de energia*

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 37 – Variação de β e R^2 para o indicador *Pessoas com ensino médio*

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

Figura 38 – Variação de β e R^2 para o indicador *Pessoas com ensino superior*

(a) Censo 1991

(b) Censo 2000

(c) Censo 2010

Fonte: Censos do IBGE de 1991, 2000 e 2010

6 Considerações finais

Os resultados obtidos foram bastante diversos. Cada caso foi, portanto, analisado considerando-se suas características e peculiaridades. A seguir são apresentadas as observações a respeito das figuras 11 a 24 e em seguida as observações relativas às figuras 25 a 38.

Para *Pessoas com acesso a saneamento básico* (figura 11), *Pessoas em moradia precária* (figura 14) e *Pessoas extremamente pobres* (figura 15), uma reta que se ajuste aos dados não é capaz de explicá-los, dados os baixos valores de R^2 calculados para os três períodos censitários. Portanto, não se fazem relevantes considerações sobre os valores de β encontrados. Vale ainda observar que o aspecto das figuras 14a e 14b se deve ao fato de não haver dados disponíveis para os respectivos indicadores e períodos censitários.

Para *Anos vividos* (figura 12), para *Crianças e jovens na escola* (figura 19) e para *Pessoas com abastecimento de energia* (figura 22) o modelo é bastante explicativo do fenômeno pelos altos valores de R^2 . Para esses três indicadores e para os três períodos censitários foram calculados valores de β muito próximos de 1. Isto significa que há crescimento linear na escala logarítmica deste indicador de acordo com o tamanho das cidades. Em outras palavras, o tamanho das cidades não tem impacto no total de anos de vividos pela população, na proporção de crianças e jovens na escola e na proporção de pessoas atendidas com abastecimento de energia elétrica.

Outra observação interessante que pode ser feita é que, para os indicadores *Anos vividos* e *Pessoas com abastecimento de energia*, há uma “concentração” maior das cidades em torno da curva que se ajusta aos dados ao longo do tempo, indicando diminuição da desigualdade entre as cidades em relação a esses indicadores. Cabe ressaltar que não foi definida aqui uma métrica para caracterizar esta “concentração”, sendo assim esta observação uma característica constatada apenas visualmente.

Para *Mortes até 5 anos de idade* (figura 13) o modelo é pouco explicativo do fenômeno, uma vez que os valores de R^2 variam entre 0,49 (Censo 1991) e 0,74 (Censo 2010). Há um aumento do valor de R^2 a cada período censitário. Para os três períodos censitários os valores de β foram menores do que 1, o que indica crescimento sublinear na escala logarítmica do indicador (economia de escala).

Se considerarmos a validade do modelo para os dados, isto significa que cidades maiores apresentam menores taxas de mortalidade infantil. Quanto maior a cidade, menores serão as taxas de mortalidade infantil *per capita*. Tomando o Censo 2010 como exemplo, uma cidade com o dobro do tamanho de outra teria taxas de mortalidade infantil *per capita* 17% menores ($\beta = 0,83$), o que seria uma vantagem das cidades grandes. Assim como no caso da *Anos vividos* (figura 12), há também aqui uma “concentração” maior das cidades em torno da curva que se ajusta aos dados ao longo dos períodos censitários, indicando diminuição da desigualdade entre as cidades em relação a este indicador.

Para *Pessoas com acesso à água encanada* (figura 16) há um aumento do valor de R^2 ao longo dos períodos censitários, o que torna o modelo mais explicativo no período censitário mais recente (Censo 2010). Para os três períodos censitários os valores de β foram maiores do que 1, o que indica crescimento superlinear na escala logarítmica do indicador.

Se considerarmos a validade do modelo para os dados, isto significa que cidades maiores tem um melhor sistema de abastecimento de água. Neste caso, quanto maior a cidade, maiores são os percentuais de pessoas abastecidas com água potável sendo, assim, cidades maiores mais vantajosas neste aspecto. Contudo, para a amostra onde há melhor ajuste da reta aos dados (figura 16c) o valor obtido para β é bastante próximo de 1 ($\beta = 1,05$). Neste caso há característica linear.

Outro ponto a ser observado é que, assim como no caso da *Anos vividos* (figura 12), há também aqui uma “concentração” maior das cidades em torno da curva que se ajusta aos dados ao longo do tempo, indicando diminuição da desigualdade entre as cidades em relação a este indicador.

Tanto para *Jovens desempregados* (figura 18) como para *Desempregados* (figura 17) há uma pequena variação no valor de R^2 entre os Censos de 2000 e 2010, sendo que para o ano de 2010 o valor foi menor. Para ambos os períodos censitários os valores de β foram maiores do que 1, com valores bastante semelhantes para estes dois indicadores, o que indica crescimento superlinear.

Se considerarmos a validade do modelo para os dados, isto significa que as cidades maiores impactam as pessoas negativamente com relação ao nível de desemprego geral e desemprego entre os jovens, o que seria um efeito negativo das grandes cidades. Nestes dois casos, quanto maior a cidade, maiores são as taxas de desemprego. Comparando-se os dois períodos observa-se uma “concentração” diferente das cidades em torno da curva

que se ajusta aos dados entre os dois períodos censitários. Porém, aqui, diferentemente do ocorrido para *Anos vividos* (figura 12), esta concentração se dá com maior intensidade no período censitário mais antigo (Censo 2000). Isto indica um aumento da desigualdade entre as cidades para estes indicadores entre os períodos de 2000 e 2010.

Para *Pessoas com ensino fundamental* (figura 20), *Pessoas com ensino médio* (figura 23) e *Pessoas com ensino superior* (figura 24) foram calculados valores de β maiores do que 1 para os três períodos censitários. Isto significa que há crescimento superlinear na escala logarítmica destes indicadores de acordo com o tamanho das cidades. Em outras palavras, o tamanho das cidades tem impacto positivo nos indicadores, ou seja, as cidades maiores apresentam maiores taxas de pessoas com ensino fundamental, médio e superior completos do que as cidades menores. Para o Censo 2010, por exemplo, uma cidade com o dobro do tamanho de outra (em termos populacionais) tem uma taxa 18% maior de pessoas com ensino fundamental completo, 27% maior de pessoas com ensino médio completo e 36% maior de pessoas com ensino superior completo.

Podem ser considerados mais relevantes principalmente os resultados para *Pessoas com ensino fundamental* e para *Pessoas com ensino médio*, ambos para o Censo de 2010, os quais apresentam valores de R^2 mais elevados. Para Esses três indicadores o valor de R^2 é crescente ao longo dos anos. Também se observa uma “concentração” maior das cidades em torno da curva que se ajusta aos dados ao longo do tempo, assim como observado para *Anos vividos* (figura 12). Isto indica uma diminuição da desigualdade entre as cidades para estes indicadores ao longo do tempo.

Para *Pessoas com acesso à coleta de lixo* (figura 21) o modelo é bastante explicativo do fenômeno principalmente para o Censo 2010, para o qual $R^2 = 0,99$. Para os três períodos censitários foram calculados valores de β maiores do que 1. Todavia, para o Censo 2010, com maior valor de R^2 , o valor de β é bastante próximo de 1, o que significa que há crescimento linear na escala logarítmica deste indicador de acordo com o tamanho das cidades. Em outras palavras, o tamanho das cidades não tem impacto no indicador. Outra observação interessante decorre da comparação entre os resultados para o Censo 1991 e 2010. Para o ano de 1991 há um maior “espalhamento” das cidades em torno da reta que se ajusta aos dados, denotando uma maior desigualdade entre elas. Além disso, o valor de β para este período é maior do que para 2010 ($\beta = 1,10$ contra $\beta = 1,02$).

Aalguns dos indicadores utilizados estão relacionados a serviços básicos que, idealmente, devem ser oferecidos de maneira igualitária e universal. É o caso de *Crianças*

e jovens na escola, Pessoas com acesso à coleta de lixo, Pessoas com abastecimento de energia e Pessoas com acesso à água encanada. Os valores de β obtidos para esses quatro indicadores no Censo 2010 foi bastante próximo de 1 ($\beta = 0,95$, $\beta = 1,02$, $\beta = 1,01$ e $\beta = 1,05$, respectivamente), indicando que esses serviços realmente são ofertados de forma relativamente igualitária e universal entre as cidades.

Os indicadores de educação *Pessoas com ensino fundamental*, *Pessoas com ensino médio* e *Pessoas com ensino superior* para o Censo 2010 apresentam valores de $\beta = 1,18$, $\beta = 1,27$ e $\beta = 1,36$, respectivamente. É interessante observar dois aspectos sobre esses resultados: em primeiro lugar, esses indicadores de educação apresentam característica superlinear e, em segundo lugar, quanto maior o grau de escolaridade, mais elevada é a característica superlinear (maior é o valor de β).

Em outras palavras, as cidades maiores apresentam vantagens no que diz respeito ao acesso à educação e, além disso, as vantagens são tão maiores quanto maior o nível educacional.

Com relação às figuras 25 a 38, há de se fazer análises para cada indicador e ano censitário, já que os resultados são bastante variados. Uma tendência geral que aparece em todos os casos, exceto para *Pessoas com acesso a saneamento básico* e *Pessoas extremamente pobres*, é o aumento de R^2 com o aumento da população mínima considerada. Com o aumento da população mínima considerada, cada vez um grupo menor composto por cidades maiores torna a fazer parte da amostra. Estas guardam mais semelhanças entre si do que com pequenas cidades, o que torna mais preciso o ajuste do modelo aos dados.

Quanto aos valores de β , as análises mais relevantes feitas a seguir se referem ao trecho com população entre 50 e 500 mil habitantes nas figuras 25 a 38. Um escopo de análise considerando apenas cidades maiores, por exemplo, cidades com mais de 500 mil habitantes, perde sentido pois se deseja verificar a generalidade e validade dos modelos de lei de escala para as cidades.

Para *Pessoas com acesso a saneamento básico*, *Pessoas extremamente pobres* e *Pessoas em moradia precária* não cabe análise dos valores de β , visto o baixo grau de adequação do modelo aos dados (baixos valores de R^2).

Para *Anos vividos*, não houve variação relevante nos valores de β para nenhum período censitário, indicando que a variação na abrangência da escolha da amostra não tem impacto significativo sobre os resultados.

Para *Mortes até 5 anos de idade* cabe apenas análise para o Censo 2010, uma vez que para os outros períodos os valores de R^2 não são significativamente elevados para se poder afirmar acertivamente sobre as variações de β . Para o Censo 2010 há uma elevação do valor de R^2 conforme se avança na população mínima considerada, atingindo 0,85 para população de 100 mil habitantes e elevando-se ainda mais adiante. β calculado para uma população mínima de 50 mil habitantes vale, neste caso, 0,83, enquanto que para uma população mínima de 100 mil habitantes seu valor é de 0,92. Esta é uma diferença considerável e caberia, neste caso, uma análise mais aprofundada sobre o tamanho da população mínima a ser considerada para serem feitas afirmações sobre as características sublineares do indicador.

Para *Pessoas com acesso à água encanada*, não houve variação relevante de β para o Censo 2010. Para o Censo 1991 β variou de 1,14 para 1,06, para população mínima de 50 e 100 mil habitantes, respectivamente. Para o Censo 2000, β variou de 1,12 para 1,03, para população mínima de 50 e 100 mil habitantes. Isto mostra a sensibilidade do valor de β à população mínima considerada.

Para *Desempregados*, houve uma pequena variação relevante de β apenas para o Censo 2000. Neste caso β variou de 1,15 para 1,08, para população mínima de 50 e 100 mil habitantes, respectivamente. Isto mostra a sensibilidade do valor de β à população mínima considerada.

Para *Jovens desempregados*, houve uma pequena variação de β apenas para o Censo 2000. Neste caso β variou de 1,15 para 1,10, para população mínima de 50 e 100 mil habitantes, respectivamente. Isto mostra uma pequena sensibilidade do valor de β à população mínima considerada.

Para *Crianças e jovens na escola*, *Pessoas com acesso à coleta de lixo* e *Pessoas com abastecimento de energia*, não houve variação relevante de β . Para estes indicadores é possível afirmar que a variação da população não tem impacto sobre β .

Para *Pessoas com ensino fundamental*, houve variação significativa de β . Para o Censo 1991 β variou de 1,29 para 1,24, para população mínima de 50 e 100 mil habitantes, respectivamente. Para o Censo 2000 β variou de 1,24 para 1,15, para população mínima de 50 e 100 mil habitantes, respectivamente. E para o Censo 2010 β variou de 1,18 para 1,09, para população mínima de 50 e 100 mil habitantes, respectivamente. Isto mostra considerável sensibilidade do valor de β à população mínima considerada.

Para *Pessoas com ensino médio*, houve variação significativa de β apenas para os Censos 2000 e 2010. Para o Censo 2000 β variou de 1,31 para 1,22, para população mínima de 50 e 100 mil habitantes, respectivamente. E para o Censo 2010 β variou de 1,27 para 1,15, para população mínima de 50 e 100 mil habitantes, respectivamente. Isto mostra considerável sensibilidade do valor de β à população mínima considerada.

Para *Pessoas com ensino superior*, houve variação significativa de β apenas para os Censos 2000 e 2010. Para o Censo 2000 β variou de 1,46 para 1,35, para população mínima de 50 e 100 mil habitantes, respectivamente. E para o Censo 2010 β variou de 1,36 para 1,26, para população mínima de 50 e 100 mil habitantes, respectivamente. Isto mostra considerável sensibilidade do valor de β à população mínima considerada.

Quando se observam os resultados para a população mínima 50 mil habitantes, há concordância apenas parcialmente com a literatura que advoga pela generalidade das leis de escala. Dos 14 indicadores analisados, 3 não apresentaram qualquer regularidade que pudesse ser descrita por leis de escala. Os outros 11 indicadores seguem em boa parte as suposições feitas por Bettencourt, Lobo e Strumsky (2007).

É o caso dos indicadores de educação, que apresentam comportamento superlinear, e os indicadores de serviços básicos (fornecimento de água, coleta de lixo, abastecimento de energia), que apresentam comportamento linear.

Segundo Bettencourt, Lobo e Strumsky (2007) as maiores aglomerações urbanas propiciam maiores oportunidades de inovação e construção de conhecimento, o que explica a superlinearidade também encontrada aqui para os indicadores de educação.

Já para o caso dos serviços básicos, estes se enquadram no conjunto de indicadores atrelados à satisfação de necessidades individuais e devem, de acordo com Bettencourt, Lobo e Strumsky (2007), apresentar comportamento linear. Os indicadores aqui analisados estão em concordância com estas suposições.

É importante salientar outras considerações acerca dos resultados apresentados. Em primeiro lugar e, provavelmente a questão mais importante, é a sensibilidade de β para diferentes valores mínimos de população escolhido para o recorte da amostra. A alta sensibilidade de β para pequenas variações de população para alguns indicadores leva ao questionamento sobre a escolha de uma população mínima adotada de maneira generalizada para o estudo das leis de escala.

Os resultados considerando uma população mínima fixa podem levar a conclusões imprecisas e equivocadas. A avaliação da validade e características das leis de escala

na comparação de *indicadores vs população* deve estar, portanto, atrelada à análise da alteração dos valores de β para diferentes valores de população mínima.

Outra questão em aberto é a própria escolha do número de habitantes como grandeza a ser comparada com os indicadores. As incertezas aqui encontradas em relação às variações de β para variações da população reforçam os questionamentos colocados por Cebrat e Sobczykński (2016), Steele (2017) e Batty (2008) sobre a utilização da população para análise das leis de escala. Escolhas de grandezas como, por exemplo, densidades populacionais no lugar da população podem representar melhor o que é uma cidade. Está em revisão pelo próprio IBGE a metodologia para caracterização das áreas urbanas. A nova metodologia deve passar a incluir a densidade demográfica, localização em relação a centros urbanos e tamanho da população como parâmetros identificar as áreas verdadeiramente urbanas (IBGE, 2017).

Por fim, espera-se que o programa desenvolvido para manipulação dos dados possa ser reutilizado, aprimorado e adaptado para fins semelhantes ao dessa pesquisa ou outros quaisquer. Os *scripts* podem ser modificados, por exemplo, para se fazer a análise das leis de escala para outros indicadores, para se utilizar grandezas alternativas à população na comparação com os indicadores, para se fazer análises regionais ao invés de considerar todo o território nacional, entre outras.

Ele é uma ferramenta capaz de lidar com uma quantidade grande de dados. Isto é particularmente relevante na realidade atual, em que a quantidade de dados à disposição é cada vez maior e fazem-se necessárias ferramentas para transformá-los em informações que sejam úteis, relevantes e que possam produzir transformações na realidade.

Referências

- ABNT. ABNT NBR ISO 37120 Desenvolvimento sustentável de comunidades - Indicadores para serviços urbanos e qualidade de vida. 2017.
- ALVES, L.; RIBEIRO, H.; MENDES, R. Scaling laws in the dynamics of crime growth rate. *Physica A: Statistical Mechanics and its Applications*, v. 392, n. 11, p. 2672–2679, 2013.
- ANTONIO, F. et al. Growth patterns and scaling laws governing AIDS epidemic in Brazilian cities. *PLoS ONE*, v. 9, n. 10, 2014.
- ARCAUTE, E. et al. Constructing cities, deconstructing scaling laws. *Journal of the Royal Society Interface*, v. 12, n. 102, 2015.
- BAI, X. et al. Urban policy and governance in a global environment: Complex systems, scale mismatches and public participation. *Current Opinion in Environmental Sustainability*, v. 2, n. 3, p. 129–135, 2010.
- BALL, P.; HELBING, D. *Why society is a complex matter: Meeting twenty-first century challenges with a new kind of science*. Berlin: Springer-Verlag, 2012. 1-60 p.
- BATTY, M. The size, scale, and shape of cities. *Science*, v. 319, n. 5864, p. 769–771, 2008.
- BATTY, M. Cities as complex systems: Scaling, interaction, networks, dynamics and urban morphologies. In: _____. *Encyclopedia of Complexity and Systems Science*. New York, NY: Springer New York, 2009. p. 1041–1071.
- BATTY, M. Building a science of cities. *Cities*, v. 29, n. SUPPL. 1, p. S9–S16, 2012.
- BETTENCOURT, L. The origins of scaling in cities. *Science*, v. 340, n. 6139, p. 1438–1441, 2013.
- BETTENCOURT, L. et al. Growth, innovation, scaling, and the pace of life in cities. *Proceedings of the National Academy of Sciences of the United States of America*, v. 104, n. 17, p. 7301–7306, 2007.
- BETTENCOURT, L.; LOBO, J.; STRUMSKY, D. Invention in the city: Increasing returns to patenting as a scaling function of metropolitan size. *Research Policy*, v. 36, n. 1, p. 107–120, 2007.
- BETTENCOURT, L. et al. Urban scaling and its deviations: Revealing the structure of wealth, innovation and crime across cities. *PLoS ONE*, v. 5, n. 11, 2010.
- BETTENCOURT, L.; LOBO, J.; WEST, G. Why are large cities faster? universal scaling and self-similarity in urban organization and dynamics. *European Physical Journal B*, v. 63, n. 3, p. 285–293, 2008.
- BETTENCOURT, L.; WEST, G. A unified theory of urban living. *Nature*, v. 467, n. 7318, p. 912–913, 2010.
- BOKÁNYI, E.; SZÁLLÁSI, Z.; VATTAY, G. Universal scaling laws in metro area election results. *PLoS ONE*, v. 13, n. 2, 2018.

- CEBRAT, K.; SOBCZYŃSKI, M. Scaling laws in city growth: Setting limitations with self-organizing maps. *PLoS ONE*, v. 11, n. 12, 2016.
- CHEN, Y.; ZHOU, Y. Scaling laws and indications of self-organized criticality in urban systems. *Chaos, Solitons and Fractals*, v. 35, n. 1, p. 85–98, 2008.
- DAVIES, T. et al. Application of an entropy maximizing and dynamics model for understanding settlement structure: The khabur triangle in the middle bronze and iron ages. *Journal of Archaeological Science*, v. 43, n. 1, p. 141–154, 2014.
- DEÁK, C. Acumulação entravada no brasil e a crise dos anos 80. *Espaço & Debates*, World Scientific Publishing Co., v. 32, p. 34–46, 1991.
- FRAGKIAS, M. et al. Does size matter? Scaling of CO² emissions and U.S. urban areas. *PLoS ONE*, v. 8, n. 6, 2013.
- FULLER, R.; GASTON, K. The scaling of green space coverage in european cities. *Biology Letters*, v. 5, n. 3, p. 352–355, 2009.
- FURTADO, B.; SAKOWSKI, P.; TÓVOLI, M. Modelagem de sistemas complexos para políticas públicas. *Caderno CRH*, v. 28, n. 1, 2015.
- GIRARDET, H. *The Gaia Atlas of Cities: New Directions for Sustainable Urban Living*. London: Gaia, 1996. (A Gaia original). ISBN 9781856750974.
- GLAESER, E. *Os centros urbanos: a maior invenção da humanidade*. Rio de Janeiro: Elsevier, 2011.
- GRIMM, N. et al. Global change and the ecology of cities. *Science*, v. 319, n. 5864, p. 756–760, 2008.
- GROSS, A.; MURTHY, D.; VARSHNEY, L. Pace of life in cities and the emergence of town tweeters. *SAGE Open*, v. 7, n. 4, 2017.
- HORTA-BERNÚS, R.; ROSAS-CASALS, M. Obsolescence in urban energy infrastructures: The influence of scaling laws on consumption forecasting. *Journal of Urban Technology*, v. 22, n. 2, p. 3–17, 2015.
- IBGE. Censo demográfico 2010. *IBGE*, 2012.
- IBGE. Classificação e caracterização dos espaços rurais e urbanos do brasil: uma primeira aproximação. *Estudos & Pesquisas: Informação Geográfica*, v. 11, 2017.
- JACOBS, J. *Morte e vida de grandes cidades*. 3. ed. São Paulo: WMF Martins Fontes, 2011.
- KENNEDY, C.; PINCETL, S.; BUNJE, P. The study of urban metabolism and its applications to urban planning and design. *Environmental Pollution*, v. 159, n. 8-9, p. 1965–1973, 2011.
- KENNEDY, C. et al. Energy and material flows of megacities. *Proceedings of the National Academy of Sciences of the United States of America*, v. 112, n. 19, p. 5985–5990, 2015.
- KLEIBER, M. Body size and metabolism. *Hilgardia*, v. 6, n. 11, p. 315–353, 1932.

- KÜHNERT, C.; HELBING, D.; WEST, G. Scaling laws in urban supply networks. *Physica A: Statistical Mechanics and its Applications*, v. 363, n. 1, p. 96–103, 2006.
- LAMSAL, L. et al. Scaling relationship for NO² pollution and urban population size: A satellite perspective. *Environmental Science and Technology*, v. 47, n. 14, p. 7855–7861, 2013.
- LEVINSON, D. Network structure and city size. *PLoS ONE*, v. 7, n. 1, 2012.
- MAKSE, H. et al. Modeling urban growth patterns with correlated percolation. *Physical Review E - Statistical Physics, Plasmas, Fluids, and Related Interdisciplinary Topics*, v. 58, n. 6, p. 7054–7062, 1998.
- MARSHALL, J. Urban land area and population growth: A new scaling relationship for metropolitan expansion. *Urban Studies*, v. 44, n. 10, p. 1889–1904, 2007.
- MCPHEARSON, T. et al. Advancing urban ecology toward a science of cities. *BioScience*, v. 66, n. 3, p. 198–212, 2016.
- MITCHELL, M. *Complexity: A tour guide*. New York: Oxford University Press Inc., 2009.
- NEGREIROS, I.; ABIKO, A. Normalização técnica para cidades e comunidades sustentáveis. In: _____. *Gestão urbana e sustentabilidade*. São Paulo: Manole, 2019.
- OLIVEIRA, M.; BASTOS-FILHO, C.; MENEZES, R. The scaling of crime concentration in cities. *PLoS ONE*, v. 12, n. 8, 2017.
- PAN, W. et al. Urban characteristics attributable to density-driven tie formation. *Nature Communications*, v. 4, 2013.
- SARKAR, S. Urban scaling and the geographic concentration of inequalities by city size. *Environment and Planning B: Urban Analytics and City Science*, 2018.
- SCHLÄPFER, M. et al. The scaling of human interactions with city size. *Journal of the Royal Society Interface*, v. 11, n. 98, 2014.
- SCHMIDT-NIELSEN, K. *Scaling: Why Is Animal Size So Important?* Cambridge: Cambridge University Press, 1984.
- STEELE, M. The scaling of urban surface water abundance and impairment with city size. *Geomorphology*, 2017.
- UN. World urbanization prospects: The revision. United Nations, 2018.
- VEIGA, J. da. *Cidades imaginárias: o Brasil é menos urbano do que se calcula*. Campinas: Editora Autores Associados, 2002. ISBN 9788574960487.
- VILLAÇA, F. *Espaço intra-urbano no Brasil*. São Paulo: Studio Nobel, 1998.
- WILSON, A. Boltzmann, lotka and volterra and spatial structural evolution: An integrated methodology for some dynamical systems. *Journal of the Royal Society Interface*, v. 5, n. 25, p. 865–871, 2008.
- WOLMAN, A. The metabolism of cities. *Scientific American*, v. 213, n. 3, p. 179–190, 1965.

Anexo A – Código do arquivo *read_plot_data.py*

```

1  # -*- coding: utf-8 -*-
2  """
3  Created on Thu Nov 9 14:18:24 2017
4
5  @author: Nakano
6  """
7
8  import xlrd
9  import xlwt
10 import scipy
11 import numpy as np
12 import matplotlib.pyplot as plt
13 import math
14 import xlswriter
15 import os
16 from scipy import stats
17 from dictionary import *
18 from data_conversion import *
19 from data_conversion import convert
20 from parameters import *
21 from xlutils.copy import copy
22 from xlrd import open_workbook
23
24 def SearchColumn(ColumnToBeFound, ColumnNames, TotalColumns):
25     Index = 0
26     for i in range (1, TotalColumns):
27         if ColumnNames[Index] != ColumnToBeFound:
28             Index += 1 #get column containig year of research
29         else:
30             break
31     return Index
32
33 data_path = 'G:/My_Drive/MESTRADO/PESQUISA/DADOS_-novos/
34             atlas2013-dadosbrutos_pt.xlsx'
35
36 """

```

```

37 Open and read an Excel file
38 """
39 book = xlrd.open_workbook(data_path)
40
41 # search for index of worksheet containig cities data
42 sheet_names = book.sheet_names()
43 data_of_cities_index = 0
44 while sheet_names[data_of_cities_index] != 'MUN_91-00-10':
45     data_of_cities_index += 1
46
47 # get the worksheet containig cities data
48 cities_data = book.sheet_by_index(data_of_cities_index)
49
50 # search for column index containig the desired data (e.g. year, city code,
    state, etc.)
51 cities_data_name = cities_data.row_values(0)
52 year_col = SearchColumn('ANO', cities_data_name, cities_data.ncols)
53 city_code = SearchColumn('Codmun7', cities_data_name, cities_data.ncols)
54 population_col = SearchColumn('pesotot', cities_data_name, cities_data.ncols)
55
56 # store the content of a column, i.e. data type (e.g. expecativa de vida)
    for a given year (e.g. 2010) for all cities
57 # with with the lower threshold MIN_POP and an upper threshold MAX_POP
58
59 YEAR = 1991
60 MIN_POP = 0
61 POP_STOP = 30000
62 MAX_POP = 30000
63 INTERVAL_POP = 40000
64
65 parameters_rows = math.ceil((POP_STOP - MIN_POP )/INTERVAL_POP)
66 parameters_columns = 4 # slope, R2, min population, max population
67 parameters_indicators = len(plot_data)
68 # fill a 3D array with zeros. The array should containd a 2D array for each
    indicator. Each 2D array should contain
69 # rows with slope, R2, min population and max population
70 parameters = np.zeros([parameters_indicators, parameters_rows,
    parameters_columns])
71

```

```

72 # create path to save figures and excel file with parameters
73 newpath = str((figures_path + str(YEAR) + '/'))
74 if not os.path.exists(newpath):
75     os.makedirs(newpath)
76
77 # Create a new Excel file and add a worksheet.
78 workbook = xlswriter.Workbook(newpath + 'parameters_' + str(YEAR) + '.xlsx',
79                                {'nan_inf_to_errors': True})
79
80 new_MIN_POP = MIN_POP
81 parameters_row = 0
82 for new_MIN_POP in range(MIN_POP, POP_STOP, INTERVAL_POP):
83     #

```

```

84     # count number of rows containing population greater than MIN_POP
85     # for creation of a matrix (data)
86     #

```

```

87     row_count = 0
88     column_count = 0
89     for row in range(1, cities_data.nrows):
90         if(cities_data.cell(row, year_col).value == YEAR:
91             if ((cities_data.cell(row, population_col).value) > new_MIN_POP
92                 and
93                 (cities_data.cell(row, population_col).value) < MAX_POP):
94                 row_count = row_count + 1
95
96     # creating a data matrix with:
97     # - all rows with data and
98     # - all columns with data (plus codmun7 column)
99     data = np.zeros((row_count, cities_data.ncols - 4))
100
101     #filling the data matrix with the data from excel sheet
102     row_count = 0
103     column_count = 0
104     for row in range(1, cities_data.nrows):
105         if(cities_data.cell(row, year_col).value == YEAR:

```

```

105         if ((cities_data.cell(row, population_col).value) > new_MIN_POP
106             and
107             (cities_data.cell(row, population_col).value) < MAX_POP):
108             data[row_count, column_count] = cities_data.cell(row,
109                 city_code).value
110             row_count = row_count + 1
111
112     row_count = 0
113     column_count = 1
114     for row in range (1, cities_data.nrows):
115         if(cities_data.cell(row, year_col).value == YEAR:
116             if ((cities_data.cell(row, population_col).value) > new_MIN_POP
117                 and
118                 (cities_data.cell(row, population_col).value) < MAX_POP):
119                 for column in range (5, cities_data.ncols):
120                     if (cities_data.cell(row, column).value is ' '):
121                         data[row_count, column_count] = 0
122                     else:
123                         data[row_count, column_count] = cities_data.cell(row
124                             , column).value
125                         column_count = column_count + 1
126                 column_count = 1
127                 row_count = row_count + 1
128
129     rows = data.shape[0]
130     pop = data
131     converted_data = convert(data)
132     for i in range(converted_data.shape[0]):
133         for j in range(1, converted_data.shape[1]):
134             if(converted_data[i, j] != 0):
135                 converted_data[i, j] = math.log(converted_data[i, j], 10)
136
137     parameters_indicator = 0
138     for i in plot_data:
139         slope, intercept, r_value, p_value, std_err = scipy.stats.
140             linregress(converted_data[:, PESOTOT], converted_data[:, i])
141         fit_curve = intercept + slope * converted_data[:, PESOTOT]
142         fig = plt.figure(i)
143         ax = fig.add_subplot(111)

```

```

139
140     # store parameters in a matrix
141     parameters[parameters_indicator][parameters_row][0] = slope
142     parameters[parameters_indicator][parameters_row][1] = r_value**2
143     parameters[parameters_indicator][parameters_row][2] = new_MIN_POP
144     parameters[parameters_indicator][parameters_row][3] = MAX_POP
145     parameters_indicator = parameters_indicator + 1
146
147     for j in range(converted_data.shape[0]):
148         if (metropol_regions == True):
149             if (metropol_agreste == True):
150                 if (converted_data[j , CODMUN7] in agreste):
151                     plt.plot(converted_data[j , PESOTOT],
152                             converted_data[j,i] , 'r.')
153                 else:
154                     plt.plot(converted_data[j , PESOTOT],
155                             converted_data[j,i] , 'b.')
156             if (metropol_aracaju == True):
157                 if (converted_data[j , CODMUN7] in aracaju):
158                     plt.plot(converted_data[j , PESOTOT],
159                             converted_data[j,i] , 'r.')
160                 else:
161                     plt.plot(converted_data[j , PESOTOT],
162                             converted_data[j,i] , 'b.')
163             if (metropol_baixada_santista == True):
164                 if (converted_data[j , CODMUN7] in baixada_santista):
165                     plt.plot(converted_data[j , PESOTOT],
166                             converted_data[j,i] , 'r.')
167                 else:
168                     plt.plot(converted_data[j , PESOTOT],
169                             converted_data[j,i] , 'b.')
170             if (metropol_belem == True):

```

```

170         if (converted_data[j , CODMUN7] in belo_horizonte):
171             plt.plot(converted_data[j , PESOTOT],
172                        converted_data[j,i] , 'r. ')
173         else:
174             plt.plot(converted_data[j , PESOTOT],
175                        converted_data[j,i] , 'b. ')
176     if (metropol_campina_grande == True):
177         if (converted_data[j , CODMUN7] in campina_grande):
178             plt.plot(converted_data[j , PESOTOT],
179                        converted_data[j,i] , 'r. ')
180         else:
181             plt.plot(converted_data[j , PESOTOT],
182                        converted_data[j,i] , 'b. ')
183     if (metropol_campinas == True):
184         if (converted_data[j , CODMUN7] in campinas):
185             plt.plot(converted_data[j , PESOTOT],
186                        converted_data[j,i] , 'r. ')
187         else:
188             plt.plot(converted_data[j , PESOTOT],
189                        converted_data[j,i] , 'b. ')
190     if (metropol_carbonifera == True):
191         if (converted_data[j , CODMUN7] in carbonifera):
192             plt.plot(converted_data[j , PESOTOT],
193                        converted_data[j,i] , 'r. ')
194         else:
195             plt.plot(converted_data[j , PESOTOT],
196                        converted_data[j,i] , 'b. ')
197     if (metropol_chapeco == True):
198         if (converted_data[j , CODMUN7] in chapeco):
199             plt.plot(converted_data[j , PESOTOT],
200                        converted_data[j,i] , 'r. ')
201         else:

```

```

198         plt.plot(converted_data[j , PESOTOT],
199                  converted_data[j,i], 'b.')
200     if (metropol_curitiba == True):
201         if (converted_data[j , CODMUN7] in curitiba):
202             plt.plot(converted_data[j , PESOTOT],
203                      converted_data[j,i], 'r.')
204         else:
205             plt.plot(converted_data[j , PESOTOT],
206                      converted_data[j,i], 'b.')
207     if (metropol_distrito_federal == True):
208         if (converted_data[j , CODMUN7] in distrito_federal):
209             plt.plot(converted_data[j , PESOTOT],
210                      converted_data[j,i], 'r.')
211         else:
212             plt.plot(converted_data[j , PESOTOT],
213                      converted_data[j,i], 'b.')
214     if (metropol_florianopolis == True):
215         if (converted_data[j , CODMUN7] in florianopolis):
216             plt.plot(converted_data[j , PESOTOT],
217                      converted_data[j,i], 'r.')
218         else:
219             plt.plot(converted_data[j , PESOTOT],
220                      converted_data[j,i], 'b.')
221     if (metropol_fortaleza == True):
222         if (converted_data[j , CODMUN7] in fortaleza):
223             plt.plot(converted_data[j , PESOTOT],
224                      converted_data[j,i], 'r.')
225         else:
226             plt.plot(converted_data[j , PESOTOT],
227                      converted_data[j,i], 'b.')
228     if (metropol_foz_do_itajai == True):
229         if (converted_data[j , CODMUN7] in foz_do_itajai):
230             plt.plot(converted_data[j , PESOTOT],
231                      converted_data[j,i], 'r.')
232         else:
233             plt.plot(converted_data[j , PESOTOT],
234                      converted_data[j,i], 'b.')
235     if (metropol_goiania == True):
236         if (converted_data[j , CODMUN7] in goiania):

```

```

226         plt.plot(converted_data[j , PESOTOT] ,
227                  converted_data[j,i] , 'r.')
228     else:
229         plt.plot(converted_data[j , PESOTOT] ,
230                  converted_data[j,i] , 'b.')
231 if (metropol_grande_teresina == True):
232     if (converted_data[j , CODMUN7] in grande_teresina):
233         plt.plot(converted_data[j , PESOTOT] ,
234                  converted_data[j,i] , 'r.')
235     else:
236         plt.plot(converted_data[j , PESOTOT] ,
237                  converted_data[j,i] , 'b.')
238 if (metropol_grande_vitoria == True):
239     if (converted_data[j , CODMUN7] in grande_vitoria):
240         plt.plot(converted_data[j , PESOTOT] ,
241                  converted_data[j,i] , 'r.')
242     else:
243         plt.plot(converted_data[j , PESOTOT] ,
244                  converted_data[j,i] , 'b.')
245 if (metropol_joao_pessoa == True):
246     if (converted_data[j , CODMUN7] in joao_pessoa):
247         plt.plot(converted_data[j , PESOTOT] ,
248                  converted_data[j,i] , 'r.')
249     else:
250         plt.plot(converted_data[j , PESOTOT] ,
251                  converted_data[j,i] , 'b.')
252 if (metropol_lages == True):
253     if (converted_data[j , CODMUN7] in lages):
254         plt.plot(converted_data[j , PESOTOT] ,
255                  converted_data[j,i] , 'r.')
256     else:
257         plt.plot(converted_data[j , PESOTOT] ,
258                  converted_data[j,i] , 'b.')
259 if (metropol_londrina == True):
260     if (converted_data[j , CODMUN7] in londrina):
261         plt.plot(converted_data[j , PESOTOT] ,
262                  converted_data[j,i] , 'r.')
263     else:

```



```

253         plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'b. ')
254     if (metropol_macapa == True):
255         if (converted_data[j , CODMUN7] in macapa):
256             plt.plot(converted_data[j , PESOTOT] ,
                        converted_data[j,i] , 'r. ')
257         else:
258             plt.plot(converted_data[j , PESOTOT] ,
                        converted_data[j,i] , 'b. ')
259     if (metropol_maceio == True):
260         if (converted_data[j , CODMUN7] in maceio):
261             plt.plot(converted_data[j , PESOTOT] ,
                        converted_data[j,i] , 'r. ')
262         else:
263             plt.plot(converted_data[j , PESOTOT] ,
                        converted_data[j,i] , 'b. ')
264     if (metropol_manaus == True):
265         if (converted_data[j , CODMUN7] in manaus):
266             plt.plot(converted_data[j , PESOTOT] ,
                        converted_data[j,i] , 'r. ')
267         else:
268             plt.plot(converted_data[j , PESOTOT] ,
                        converted_data[j,i] , 'b. ')
269     if (metropol_maringa == True):
270         if (converted_data[j , CODMUN7] in maringa):
271             plt.plot(converted_data[j , PESOTOT] ,
                        converted_data[j,i] , 'r. ')
272         else:
273             plt.plot(converted_data[j , PESOTOT] ,
                        converted_data[j,i] , 'b. ')
274     if (metropol_natal == True):
275         if (converted_data[j , CODMUN7] in natal):
276             plt.plot(converted_data[j , PESOTOT] ,
                        converted_data[j,i] , 'r. ')
277         else:
278             plt.plot(converted_data[j , PESOTOT] ,
                        converted_data[j,i] , 'b. ')
279     if (metropol_norte_nordeste_catarinense == True):

```

```

280         if (converted_data[j , CODMUN7] in
                norte_nordeste_catarinense):
281             plt.plot(converted_data[j , PESOTOT],
                        converted_data[j,i] , 'r.')
282         else:
283             plt.plot(converted_data[j , PESOTOT],
                        converted_data[j,i] , 'b.')
284     if (metropol_petrolina_juazeiro == True):
285         if (converted_data[j , CODMUN7] in petrolina_juazeiro):
286             plt.plot(converted_data[j , PESOTOT],
                        converted_data[j,i] , 'r.')
287         else:
288             plt.plot(converted_data[j , PESOTOT],
                        converted_data[j,i] , 'b.')
289     if (metropol_porto_alegre == True):
290         if (converted_data[j , CODMUN7] in porto_alegre):
291             plt.plot(converted_data[j , PESOTOT],
                        converted_data[j,i] , 'r.')
292         else:
293             plt.plot(converted_data[j , PESOTOT],
                        converted_data[j,i] , 'b.')
294     if (metropol_recife == True):
295         if (converted_data[j , CODMUN7] in recife):
296             plt.plot(converted_data[j , PESOTOT],
                        converted_data[j,i] , 'r.')
297         else:
298             plt.plot(converted_data[j , PESOTOT],
                        converted_data[j,i] , 'b.')
299     if (metropol_rio_de_janeiro == True):
300         if (converted_data[j , CODMUN7] in rio_de_janeiro):
301             plt.plot(converted_data[j , PESOTOT],
                        converted_data[j,i] , 'r.')
302         else:
303             plt.plot(converted_data[j , PESOTOT],
                        converted_data[j,i] , 'b.')
304     if (metropol_salvador == True):
305         if (converted_data[j , CODMUN7] in salvador):
306             plt.plot(converted_data[j , PESOTOT],
                        converted_data[j,i] , 'r.')

```

```

307         else:
308             plt.plot(converted_data[j , PESOTOT],
309                      converted_data[j,i] , 'b. ')
310     if (metropol_sao_luis == True):
311         if (converted_data[j , CODMUN7] in sao_luis):
312             plt.plot(converted_data[j , PESOTOT],
313                      converted_data[j,i] , 'r. ')
314         else:
315             plt.plot(converted_data[j , PESOTOT],
316                      converted_data[j,i] , 'b. ')
317     if (metropol_sao_paulo == True):
318         if (converted_data[j , CODMUN7] in sao_paulo):
319             plt.plot(converted_data[j , PESOTOT],
320                      converted_data[j,i] , 'r. ')
321         else:
322             plt.plot(converted_data[j , PESOTOT],
323                      converted_data[j,i] , 'b. ')
324     if (metropol_sudoeste_maranhense == True):
325         if (converted_data[j , CODMUN7] in sudoeste_maranhense):
326             :
327             plt.plot(converted_data[j , PESOTOT],
328                      converted_data[j,i] , 'r. ')
329         else:
330             plt.plot(converted_data[j , PESOTOT],
331                      converted_data[j,i] , 'b. ')
332     if (metropol_tubarao == True):
333         if (converted_data[j , CODMUN7] in tubarao):
334             plt.plot(converted_data[j , PESOTOT],
335                      converted_data[j,i] , 'r. ')
336         else:
337             plt.plot(converted_data[j , PESOTOT],
338                      converted_data[j,i] , 'b. ')
339     if (metropol_vale_do_aco == True):
340         if (converted_data[j , CODMUN7] in vale_do_aco):
341             plt.plot(converted_data[j , PESOTOT],
342                      converted_data[j,i] , 'r. ')
343         else:
344             plt.plot(converted_data[j , PESOTOT],
345                      converted_data[j,i] , 'b. ')

```

```

334         if (metropol_vale_do_itajai == True):
335             if (converted_data[j , CODMUN7] in vale_do_itajai):
336                 plt.plot(converted_data[j , PESOTOT],
337                          converted_data[j,i] , 'r.')
338             else:
339                 plt.plot(converted_data[j , PESOTOT],
340                          converted_data[j,i] , 'b.')
341         if (metropol_vale_rio_cuiaba == True):
342             if (converted_data[j , CODMUN7] in vale_rio_cuiaba):
343                 plt.plot(converted_data[j , PESOTOT],
344                          converted_data[j,i] , 'r.')
345             else:
346                 plt.plot(converted_data[j , PESOTOT],
347                          converted_data[j,i] , 'b.')
348
349     elif(capitals == True):
350         if (converted_data[j , CODMUN7] in capitals_list):
351             plt.plot(converted_data[j , PESOTOT], converted_data[j ,
352                          i] , 'r.')
353         else:
354             plt.plot(converted_data[j , PESOTOT], converted_data[j ,
355                          i] , 'b.')
356
357     elif(states == True):
358         if (RO == True):
359             if (converted_data[j , CODMUN7] in RO_list):
360                 plt.plot(converted_data[j , PESOTOT],
361                          converted_data[j,i] , 'r.')
362             else:
363                 plt.plot(converted_data[j , PESOTOT],
364                          converted_data[j,i] , 'b.')
365         if (AC == True):
366             if (converted_data[j , CODMUN7] in AC_list):
367                 plt.plot(converted_data[j , PESOTOT],
368                          converted_data[j,i] , 'r.')
369             else:
370                 plt.plot(converted_data[j , PESOTOT],
371                          converted_data[j,i] , 'b.')
372         if (AM == True):

```

```

363         if (converted_data[j , CODMUN7] in AM_list):
364             plt.plot(converted_data[j , PESOTOT] ,
                       converted_data[j,i] , 'r. ')
365         else:
366             plt.plot(converted_data[j , PESOTOT] ,
                       converted_data[j,i] , 'b. ')
367     if (RR == True):
368         if (converted_data[j , CODMUN7] in RR_list):
369             plt.plot(converted_data[j , PESOTOT] ,
                       converted_data[j,i] , 'r. ')
370         else:
371             plt.plot(converted_data[j , PESOTOT] ,
                       converted_data[j,i] , 'b. ')
372     if (PA == True):
373         if (converted_data[j , CODMUN7] in PA_list):
374             plt.plot(converted_data[j , PESOTOT] ,
                       converted_data[j,i] , 'r. ')
375         else:
376             plt.plot(converted_data[j , PESOTOT] ,
                       converted_data[j,i] , 'b. ')
377     if (AP == True):
378         if (converted_data[j , CODMUN7] in AP_list):
379             plt.plot(converted_data[j , PESOTOT] ,
                       converted_data[j,i] , 'r. ')
380         else:
381             plt.plot(converted_data[j , PESOTOT] ,
                       converted_data[j,i] , 'b. ')
382     if (TO == True):
383         if (converted_data[j , CODMUN7] in TO_list):
384             plt.plot(converted_data[j , PESOTOT] ,
                       converted_data[j,i] , 'r. ')
385         else:
386             plt.plot(converted_data[j , PESOTOT] ,
                       converted_data[j,i] , 'b. ')
387     if (MA == True):
388         if (converted_data[j , CODMUN7] in MA_list):
389             plt.plot(converted_data[j , PESOTOT] ,
                       converted_data[j,i] , 'r. ')
390         else:

```

```

391         plt.plot(converted_data[j , PESOTOT] ,
392                  converted_data[j,i] , 'b. ')
393     if (PI == True):
394         if (converted_data[j , CODMUN7] in PI_list):
395             plt.plot(converted_data[j , PESOTOT] ,
396                      converted_data[j,i] , 'r. ')
397         else:
398             plt.plot(converted_data[j , PESOTOT] ,
399                      converted_data[j,i] , 'b. ')
400     if (CE == True):
401         if (converted_data[j , CODMUN7] in CE_list):
402             plt.plot(converted_data[j , PESOTOT] ,
403                      converted_data[j,i] , 'r. ')
404         else:
405             plt.plot(converted_data[j , PESOTOT] ,
406                      converted_data[j,i] , 'b. ')
407     if (RN == True):
408         if (converted_data[j , CODMUN7] in RN_list):
409             plt.plot(converted_data[j , PESOTOT] ,
410                      converted_data[j,i] , 'r. ')
411         else:
412             plt.plot(converted_data[j , PESOTOT] ,
413                      converted_data[j,i] , 'b. ')
414     if (PB == True):
415         if (converted_data[j , CODMUN7] in PB_list):
416             plt.plot(converted_data[j , PESOTOT] ,
417                      converted_data[j,i] , 'r. ')
418         else:
419             plt.plot(converted_data[j , PESOTOT] ,
420                      converted_data[j,i] , 'b. ')
421     if (PE == True):
422         if (converted_data[j , CODMUN7] in PE_list):
423             plt.plot(converted_data[j , PESOTOT] ,
424                      converted_data[j,i] , 'r. ')
425         else:
426             plt.plot(converted_data[j , PESOTOT] ,
427                      converted_data[j,i] , 'b. ')
428     if (AL == True):
429         if (converted_data[j , CODMUN7] in AL_list):

```

```

419         plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'r. ')
420     else:
421         plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'b. ')
422 if (SE == True):
423     if (converted_data[j , CODMUN7] in SE_list):
424         plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'r. ')
425     else:
426         plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'b. ')
427 if (BA == True):
428     if (converted_data[j , CODMUN7] in BA_list):
429         plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'r. ')
430     else:
431         plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'b. ')
432 if (MG == True):
433     if (converted_data[j , CODMUN7] in MG_list):
434         plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'r. ')
435     else:
436         plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'b. ')
437 if (ES == True):
438     if (converted_data[j , CODMUN7] in ES_list):
439         plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'r. ')
440     else:
441         plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'b. ')
442 if (RJ == True):
443     if (converted_data[j , CODMUN7] in RJ_list):
444         plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'r. ')
445     else:

```

```

446         plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'b. ')
447     if (SP == True):
448         if (converted_data[j , CODMUN7] in SP_list):
449             plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'r. ')
450         else:
451             plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'b. ')
452     if (PR == True):
453         if (converted_data[j , CODMUN7] in PR_list):
454             plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'r. ')
455         else:
456             plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'b. ')
457     if (SC == True):
458         if (converted_data[j , CODMUN7] in SC_list):
459             plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'r. ')
460         else:
461             plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'b. ')
462     if (RS == True):
463         if (converted_data[j , CODMUN7] in RS):
464             plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'r. ')
465         else:
466             plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'b. ')
467     if (MS == True):
468         if (converted_data[j , CODMUN7] in MS_list):
469             plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'r. ')
470         else:
471             plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'b. ')
472     if (MT == True):
473         if (converted_data[j , CODMUN7] in MT_list):

```



```

474         plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'r. ')
475     else:
476         plt.plot(converted_data[j , PESOTOT] ,
                    converted_data[j,i] , 'b. ')
477     if (GO == True):
478         if (converted_data[j , CODMUN7] in GO_list):
479             plt.plot(converted_data[j , PESOTOT] ,
                        converted_data[j,i] , 'r. ')
480         else:
481             plt.plot(converted_data[j , PESOTOT] ,
                        converted_data[j,i] , 'b. ')
482     if (DF == True):
483         if (converted_data[j , CODMUN7] in DF_list):
484             plt.plot(converted_data[j , PESOTOT] ,
                        converted_data[j,i] , 'r. ')
485         else:
486             plt.plot(converted_data[j , PESOTOT] ,
                        converted_data[j,i] , 'b. ')
487
488     elif(regions == True):
489         city_found = False
490         if (norte == True):
491             if (converted_data[j , CODMUN7] in RO_list or
492                 converted_data[j , CODMUN7] in AC_list or
493                 converted_data[j , CODMUN7] in AM_list or
494                 converted_data[j , CODMUN7] in RR_list or
495                 converted_data[j , CODMUN7] in PA_list or
496                 converted_data[j , CODMUN7] in TO_list):
497                 plt.plot(converted_data[j , PESOTOT] ,
                            converted_data[j,i] , 'y. ')
498                 city_found = True
499         if (nordeste == True):
500             if (converted_data[j , CODMUN7] in MA_list or
501                 converted_data[j , CODMUN7] in PI_list or
502                 converted_data[j , CODMUN7] in CE_list or
503                 converted_data[j , CODMUN7] in RN_list or
504                 converted_data[j , CODMUN7] in PB_list or
505                 converted_data[j , CODMUN7] in PE_list or

```

```

506         converted_data[j , CODMUN7] in AL_list or
507         converted_data[j , CODMUN7] in SE_list or
508         converted_data[j , CODMUN7] in BA_list):
509             plt.plot(converted_data[j , PESOTOT],
510                      converted_data[j,i] , 'g. ')
511             city_found = True
512     if (centro_oeste == True):
513         if (converted_data[j , CODMUN7] in MS_list or
514             converted_data[j , CODMUN7] in MT_list or
515             converted_data[j , CODMUN7] in GO_list or
516             converted_data[j , CODMUN7] in DF_list):
517             plt.plot(converted_data[j , PESOTOT],
518                      converted_data[j,i] , 'r. ')
519             city_found = True
520     if (sudeste == True):
521         if (converted_data[j , CODMUN7] in MG_list or
522             converted_data[j , CODMUN7] in ES_list or
523             converted_data[j , CODMUN7] in RJ_list or
524             converted_data[j , CODMUN7] in SP_list):
525             plt.plot(converted_data[j , PESOTOT],
526                      converted_data[j,i] , 'c. ')
527             city_found = True
528     if (sul == True):
529         if (converted_data[j , CODMUN7] in PR_list or
530             converted_data[j , CODMUN7] in SC_list or
531             converted_data[j , CODMUN7] in RS_list):
532             plt.plot(converted_data[j , PESOTOT],
533                      converted_data[j,i] , 'm. ')
534             city_found = True
535     if (city_found != True):
536         plt.plot(converted_data[j , PESOTOT], converted_data[j ,
537                      i] , 'b. ')
538
539     else:
540         plt.plot(converted_data[j , PESOTOT], converted_data[j,i] ,
541                  'b. ')
542
543     # Plot curve indicator x population
544     plt.plot(converted_data[: , PESOTOT], fit_curve , color='grey' , )

```

```

539     plt.title(data_names[i])
540     plt.xlabel('log(' + data_names[PESOTOT] + ')')
541     plt.ylabel('log(' + data_names[i] + ')')
542     plt.text(0.8, 0.15, r'$\beta_{\_\{}}$'.format("%.3f" % slope), ha='left',
              va='center', transform=ax.transAxes)
543     plt.text(0.8, 0.1, r'$R^2_{\_\{}}$'.format("%.3f" % r_value**2), ha='left',
              va='center', transform=ax.transAxes)
544
545     firures_path = str(newpath + str(new_MIN_POP) + '-' + str(MAX_POP)
                       + '/')
546     if not os.path.exists(firures_path):
547         os.makedirs(firures_path)
548     plt.savefig(firures_path + str(data_filenames[i]) + '-' + str(YEAR)
                + '.pdf')
549     plt.close(fig)
550
551     parameters_row = parameters_row + 1
552
553     # Write the parameters matrix in an Excel file.
554     for k in range(parameters_indicators):
555
556         worksheet = workbook.add_worksheet(str(data_filenames[plot_data[k]]))
557         worksheet.write('A1', 'beta')
558         worksheet.write('B1', 'R2')
559         worksheet.write('C1', 'min_pop')
560         worksheet.write('D1', 'max_pop')
561         for i in range(parameters_rows):
562             for j in range(parameters_columns):
563                 worksheet.write(i + 1, j, parameters[k][i][j])
564     #
565     # Plot curve beta and R2 x population cut
566     fig, ax1 = plt.subplots()
567
568     color = 'tab:green'
569     ax1.set_xlabel('recorte_da_populacao')
570     ax1.set_ylabel(r'$\beta$', color=color)
571     ax1.plot(parameters[k,:,2], parameters[k,:,0], color=color)
572     ax1.tick_params(axis='y', labelcolor=color)
573

```

```

574     ax2 = ax1.twinx() # instantiate a second axes that shares the same x-
        axis
575
576     color = 'tab:orange'
577     ax2.set_ylabel(r'$R^2$', color=color) # we already handled the x-label
        with ax1
578     ax2.plot(parameters[k,:,2], parameters[k,:,1], color=color)
579     ax2.tick_params(axis='y', labelcolor=color)
580
581     plt.title(str(data_names[plot_data[k]]))
582
583     fig.tight_layout() # otherwise the right y-label is slightly clipped
584
585     if not os.path.exists(newpath):
586         os.makedirs(newpath)
587     plt.savefig(newpath + 'Beta_R2_' + str(data_filenames[plot_data[k]]) +
        '_' + str(YEAR) + '.pdf')
588     plt.close(fig)
589 #-----
590     workbook.close()
591
592 #-----

```

Anexo B – Indicadores da Norma ABNT NBR ISO 37120:2017

Tabela 4 – Indicadores essenciais e de apoio presentes na Norma ABNT NBR ISO 37120:2017

	indicador essencial	indicador de apoio
Economia	<ul style="list-style-type: none"> • Taxa de desemprego da cidade • Valor de avaliação de propriedades comerciais e industriais como uma porcentagem do valor de avaliação total de todas as propriedades • Porcentagem da população abaixo da linha de pobreza 	<ul style="list-style-type: none"> • Porcentagem da população com emprego em tempo integral • Taxa de desemprego de jovens • Número de empresas por 100.000 habitantes • Número de novas patentes por 100.000 habitantes por ano
Educação	<ul style="list-style-type: none"> • Porcentagem da população feminina em idade escolar matriculada em escolas • Porcentagem de estudantes com ensino primário completo • Porcentagem de estudantes com ensino secundário completo • Relação estudante/professor no ensino primário 	<ul style="list-style-type: none"> • Porcentagem de população masculina em idade escolar matriculada em escolas • Porcentagem de população em idade escolar matriculada em escolas • Número de indivíduos com ensino superior completo por 100 000 habitantes
Energia	<ul style="list-style-type: none"> • Uso de energia elétrica residencial total per capita (kWh/ano) • Porcentagem de habitantes da cidade com fornecimento regular de energia elétrica • Consumo de energia de edifícios públicos por ano (kWh/m²) • Porcentagem da energia total proveniente de fontes renováveis, como parte do consumo total de energia da cidade 	<ul style="list-style-type: none"> • Uso total de energia elétrica per capita (kWh/ano) • Número médio de interrupções de energia elétrica por consumidor por ano • Duração média das interrupções de energia elétrica (em horas)
Meio Ambiente	<ul style="list-style-type: none"> • Concentração de material particulado fino (PM 2.5) • Concentração de material particulado (PM 10) • Emissão de gases de efeito de estufa medida, em toneladas per capita 	<ul style="list-style-type: none"> • Concentração de NO₂ (dióxido de nitrogênio) • Concentração de SO₂ (dióxido de enxofre) • Concentração de O₃ (ozônio) • Poluição sonora • Variação percentual em número de espécies nativas

Contiua na próxima página

Tabela 4 – continuação da página anterior

	indicador essencial	indicador de apoio
Finanças	<ul style="list-style-type: none"> • Taxa de endividamento (expansão do serviço da dívida como uma porcentagem da receita própria do município) 	<ul style="list-style-type: none"> • Despesas de capital como porcentagem de despesas totais • Porcentagem da receita própria em função do total das receitas • Porcentagem dos impostos recolhidos em função dos impostos cobrados
Resposta a incêndios e emergências	<ul style="list-style-type: none"> • Número de bombeiros por 100.000 habitantes • Número de mortes relacionadas a incêndios por 100.000 habitantes • Número de mortes relacionadas a desastres naturais por 100.000 habitantes 	<ul style="list-style-type: none"> • Número de bombeiros voluntários e em tempo parcial por 100 000 habitantes • Tempo de resposta dos serviços de emergência a partir do primeiro chamado • Tempo de resposta do Corpo de Bombeiros a partir do primeiro chamado
Governança	<ul style="list-style-type: none"> • Porcentagem de participação dos eleitores nas últimas eleições municipais em função do total de eleitores aptos votar • Porcentagem de mulheres eleitas em função do número total de eleitos na gestão da cidade 	<ul style="list-style-type: none"> • Porcentagem de mulheres empregadas na gestão da cidade • Número de condenações de servidores da cidade por corrupção e/ou suborno por 100.000 habitantes • Representação de cidadãos: número de autoridades locais eleitas para o cargo por 100.000 habitantes • Porcentagem de eleitores registrados em função da população com idade para votar
Saúde	<ul style="list-style-type: none"> • Expectativa média de vida • Número de leitos hospitalares por 100.000 habitantes • Número de médicos por 100.000 habitantes • Taxa de mortalidade de crianças menores de cinco anos a cada 1000 nascidos vivos 	<ul style="list-style-type: none"> • Número de pessoas da equipe de enfermagem e obstetrícia por 100.000 habitantes • Número de profissionais de saúde mental por 100.000 habitantes • Taxa de suicídio por 100.000 habitantes
Recreação		<ul style="list-style-type: none"> • Área, em metros quadrados de espaços públicos de recreação cobertos <i>per capita</i> • Área, em metros quadrados de espaços públicos de recreação ao ar livre <i>per capita</i>

Contiua na próxima página

Tabela 4 – continuação da página anterior

	indicador essencial	indicador de apoio
Segurança	<ul style="list-style-type: none"> • Número de agentes de polícia por 100.000 habitantes • Número de homicídios por 100.000 habitantes 	<ul style="list-style-type: none"> • Crimes contra a propriedade por 100.000 habitantes • Tempo de resposta da polícia a partir do primeiro chamado • Taxa de crimes violentos por 100.000 habitantes
Habitação	<ul style="list-style-type: none"> • Porcentagem da população urbana morando em favelas 	<ul style="list-style-type: none"> • Número de sem-teto por 100.000 habitantes • Porcentagem de moradias sem títulos de propriedade registrados
Resíduos Sólidos	<ul style="list-style-type: none"> • Porcentagem da população urbana com coleta regular de lixo (domiciliar) • Total de coleta de resíduos sólidos municipais <i>per capita</i> • Porcentagem de resíduos sólidos urbanos que são reciclados 	<ul style="list-style-type: none"> • Porcentagem de resíduos sólidos urbanos dispostos em aterros sanitários • Porcentagem de resíduos sólidos urbanos descartados para incineração • Porcentagem de resíduos sólidos urbanos queimados a céu aberto • Porcentagem de resíduos sólidos urbanos dispostos a céu aberto • Porcentagem de resíduos sólidos urbanos dispostos por outros meios • Geração de resíduos perigosos <i>per capita</i> • Porcentagem de resíduos urbanos perigosos que são reciclados
Telecomunicações e inovação	<ul style="list-style-type: none"> • Número de conexões de internet por 100.000 habitantes • Número de conexões de telefone celular por 100.000 habitantes 	<ul style="list-style-type: none"> • Número de conexões de telefone fixo por 100.000 habitantes
Transporte	<ul style="list-style-type: none"> • Quilômetros de sistema de transporte público de alta capacidade por 100.000 habitantes • Quilômetros de sistema de transporte público de média capacidade por 100.000 habitantes • Número anual de viagens em transporte público <i>per capita</i> • Número de automóveis privados <i>per capita</i> 	<ul style="list-style-type: none"> • Porcentagem de passageiros que se deslocam para o trabalho de forma alternativa ao automóvel privado • Número de veículos motorizados de duas rodas <i>per capita</i> • Quilômetros de ciclovias e ciclofaixas por 100.000 habitantes • Mortalidades de trânsito por 100.000 habitantes • Conectividade aérea (número de partidas de vôos comerciais sem escalas)

Contiua na próxima página

Tabela 4 – continuação da página anterior

	indicador essencial	indicador de apoio
Planejamento urbano	<ul style="list-style-type: none"> • Áreas verdes (hectares) por 100.000 habitantes 	<ul style="list-style-type: none"> • Número de árvores plantadas anualmente por 100.000 habitantes • Porcentagem de área de assentamentos informais em função da área total da cidade • Relação empregos/habitação
Esgotos	<ul style="list-style-type: none"> • Porcentagem da população da cidade atendida por sistemas de coleta e afastamento de esgoto • Porcentagem do esgoto da cidade que não recebeu qualquer tratamento • Porcentagem do esgoto da cidade que recebe tratamento primário • Porcentagem do esgoto da cidade que recebe tratamento secundário • Porcentagem do esgoto da cidade que recebe tratamento terciário 	
Água e saneamento	<ul style="list-style-type: none"> • Porcentagem da população da cidade com serviço de abastecimento de água potável • Porcentagem da população da cidade com acesso sustentável a uma fonte de água adequada para consumo • Porcentagem da população da cidade com acesso a saneamento melhorado • Consumo doméstico total de água <i>per capita</i> (litros por dia) 	<ul style="list-style-type: none"> • Consumo total de água <i>per capita</i> (litros por dia) • Valor médio anual de horas de interrupção do abastecimento de água por domicílio • Porcentagem de perdas de água (água não faturada)

Fonte: ABNT (2017)

Anexo C – Definição dos indicadores utilizados do Censo

Tabela 5 – Indicadores utilizados do Censo e suas definições

Nome do indicador	Definição
Taxa de desocupação - 18 anos ou mais	Percentual da população economicamente ativa (PEA) nessa faixa etária que estava desocupada, ou seja, que não estava ocupada na semana anterior à data do Censo mas havia procurado trabalho ao longo do mês anterior à data dessa pesquisa
Taxa de desocupação - 18 a 24 anos	Percentual da população economicamente ativa (PEA) nessa faixa etária que estava desocupada, ou seja, que não estava ocupada na semana anterior à data do Censo mas havia procurado trabalho ao longo do mês anterior à data dessa pesquisa
% de extremamente pobres	Proporção dos indivíduos com renda domiciliar per capita igual ou inferior a R\$ 70,00 mensais, em reais de agosto de 2010. O universo de indivíduos é limitado àqueles que vivem em domicílios particulares permanentes
% de 18 anos ou mais com fundamental completo	Razão entre a população de 18 anos ou mais de idade que concluiu o ensino fundamental, em quaisquer de suas modalidades (regular seriado, não seriado, EJA ou supletivo) e o total de pessoas nesta faixa etária multiplicado por 100
% de 25 anos ou mais com médio completo	Razão entre a população de 25 anos ou mais de idade que concluiu o ensino médio, em quaisquer de suas modalidades (regular seriado, não seriado, EJA ou supletivo) e o total de pessoas nesta faixa etária multiplicado por 100. Foram consideradas como tendo concluído o ensino médio as pessoas frequentando a 4ª série desse nível
% de 6 a 17 anos na escola	Razão entre população de 6 a 17 anos de idade que estava frequentando a escola, em qualquer nível ou série e a população total nesta faixa etária multiplicado por 100
% de 25 anos ou mais com superior completo	Razão entre a população de 25 anos ou mais de idade que concluiu pelo menos a graduação do ensino superior e o total de pessoas nesta faixa etária multiplicado por 100
% da população em domicílios com energia elétrica	Razão entre a população que vive em domicílios particulares permanentes com iluminação elétrica e a população total residente em domicílios particulares permanentes multiplicado por 100. Considera-se iluminação proveniente ou não de uma rede geral, com ou sem medidor
Esperança de vida ao nascer	Número médio de anos que as pessoas deverão viver a partir do nascimento, se permanecerem constantes ao longo da vida o nível e o padrão de mortalidade por idade prevalentes no ano do Censo
Mortalidade até 5 anos de idade	Probabilidade de morrer entre o nascimento e a idade exata de 5 anos, por 1000 crianças nascidas vivas
% de pessoas em domicílios com paredes inadequadas	Razão entre as pessoas que vivem em domicílios cujas paredes não são de alvenaria nem de madeira aparelhada e a população total residente em domicílios particulares permanentes multiplicado por 100. São considerados apenas os domicílios particulares permanentes
% da população em domicílios com coleta de lixo	Razão entre a população que vive em domicílios com coleta de lixo e a população total residente em domicílios particulares permanentes multiplicado por 100. Estão incluídas as situações em que a coleta de lixo realizada diretamente por empresa pública ou privada, ou o lixo é depositado em caçamba, tanque ou depósito fora do domicílio, para posterior coleta pela prestadora do serviço. São considerados apenas os domicílios particulares permanentes localizados em área urbana
% de pessoas em domicílios com abastecimento de água e esgotamento sanitário inadequados	Razão entre as pessoas que vivem em domicílios cujo abastecimento de água não provem de rede geral e cujo esgotamento sanitário não é realizado por rede coletora de esgoto ou fossa séptica e a população total residente em domicílios particulares permanentes multiplicado por 100. São considerados apenas os domicílios particulares permanentes
% da população em domicílios com água encanada	Razão entre a população que vive em domicílios particulares permanentes com água canalizada para um ou mais cômodos e a população total residente em domicílios particulares permanentes multiplicado por 100. A água pode ser proveniente de rede geral, de poço, de nascente ou de reservatório abastecido por água das chuvas ou carro-pipa

Fonte: IBGE (2012)