

Dados agregados, realidades ocultas: desafios na análise de ambientes obesogênicos

Aggregated data, hidden realities:
challenges in the analysis of obesogenic environments

Gustavo Henrique Campos de FARIA [1]

Resumo

O artigo explora os desafios dos dados censitários na análise de ambientes obesogênicos, destacando como a agregação de dados pode ocultar disparidades espaciais e sociais. Utilizando um modelo computacional no ArcGIS®, o estudo investiga a obesogenicidade em um bairro de Belo Horizonte, demonstrando como técnicas geoespaciais podem revelar padrões encobertos pela estatística convencional. Os resultados apontam a necessidade de abordagens mais detalhadas para compreender as dinâmicas urbanas relacionadas à saúde pública, contribuindo para políticas mais eficazes de planejamento urbano e promoção da saúde.

Palavras-chave: saúde urbana; obesidade; sintaxe espacial.

Abstract

The article addresses challenges related to using census data in the analysis of obesogenic environments, highlighting that data aggregation can conceal spatial and social disparities. Using a computational model in the software ArcGIS®, the study investigates obesogenicity in a neighborhood in the city of Belo Horizonte and shows that geospatial techniques can reveal patterns hidden by conventional statistics. The results underline the need for more detailed approaches to promote the understanding of urban dynamics related to public health and contribute to more effective urban planning and health promotion policies.

Keywords: urban health; obesity; space syntax.



Introdução

A relação entre o ambiente construído e a saúde pública tem sido amplamente estudada, destacando-se a influência da estrutura urbana na mobilidade, acessibilidade e qualidade de vida. A configuração do espaço pode favorecer ou dificultar escolhas saudáveis, impactando o bem-estar coletivo. Nesse contexto, a pesquisa sobre ambientes obesogênicos analisa elementos urbanos que influenciam hábitos alimentares e atividade física, mapeando dispersões para subsidiar políticas públicas no manejo da obesidade.

A obesidade, fenômeno multifatorial de crescente relevância global, resulta da interação complexa entre fatores biológicos, sociais, culturais e ambientais (Downs et al., 2020; Egger e Swinburn, 1997; Matozinhos et al., 2022). Ambientes obesogênicos são caracterizados pelo acesso limitado a alimentos saudáveis, ampla oferta de processados e ultraprocessados e precarização de espaços públicos que deveriam promover a vida ativa nas cidades (Faria, Souza e Mendes, 2024).

A análise desses ambientes depende de uma compreensão detalhada de diversas variáveis, sendo que a principal fonte de dados utilizada é o Censo Demográfico. Embora forneça um panorama abrangente da estrutura socioeconômica e demográfica das cidades, sua metodologia de agregação de dados pode ocultar desigualdades intraurbanas e mascarar padrões locais essenciais para a identificação de áreas de maior vulnerabilidade à doença. A categorização e espacialização dos dados censitários frequentemente resultam em representações que nem sempre refletem com precisão a escala de análise das dinâmicas urbanas, uma vez

que a homogeneização de grandes áreas geográficas dilui contrastes críticos, dificultando a identificação de locais obesogênicos.


Diante desse cenário, este estudo investiga a influência da granularidade dos dados censitários na análise dos ambientes obesogênicos, utilizando curvas de distribuição normal para demonstrar como diferentes níveis de agregação impactam a identificação de padrões espaciais. Para isso, foi realizado um estudo de caso no bairro Santa Tereza, em Belo Horizonte, Minas Gerais, Brasil, integrando métodos geoespaciais avançados e conceitos da epistemologia da complexidade para uma análise crítica do planejamento urbano e sua relação com a saúde pública.

Fundamentação teórica e conceitual

A compreensão dos ambientes obesogênicos exige uma abordagem complexa e interdisciplinar que relacione espaço, comportamento social e saúde pública. O modelo ecológico da obesidade (Figura 1), proposto por Egger e Swinburn (1997), reforça essa perspectiva ao considerar a obesidade como uma resposta normal a um ambiente anormal no qual fatores espaciais influenciam hábitos alimentares e prática de atividade física.

No contexto urbano, a escassez de acesso a alimentos saudáveis, a ampla oferta de processados e ultraprocessados e a precarização de espaços públicos favorecem o crescimento do número de casos de obesidade. Além disso, a estrutura viária e a distribuição dos estabelecimentos alimentares determinam o acesso a diferentes produtos e serviços.

Figura 1 – Modelo ecológico da obesidade



Fonte: traduzido e editado pelo autor, em 2022; adaptado de Egger e Swinburn (1997).

A análise configuracional do espaço urbano tem se mostrado uma ferramenta eficaz para compreender essas dinâmicas. Inicialmente baseada em abordagens quantitativas, essa perspectiva evoluiu para integrar aspectos sociais e espaciais, como na Teoria da Sintaxe Espacial (Hillier, 2007; Hillier e Hanson, 1984), que utiliza conceitos da topologia para examinar a relação entre organização espacial e os fenômenos sociais (Netto, 2016). Essa teoria utiliza de métricas como conectividade, relação de escolha e medida de integração¹ para mapear e analisar padrões de movimento e acessibilidade.

Análises de segmentos (Turner, 2001), de redes urbanas (Sevtsuk, 2014; Sevtsuk e Mekonnen, 2012) e modelos de gravidade (Haynes e Fotheringham, 1985; Jensen-Butler, 1972) ampliam a precisão e escopo dessa abordagem, permitindo identificar territórios mais propensos à obesidade ao examinarem a relação entre elementos espaciais e formas sociais. Esses modelos analisam os edifícios como elementos atrativos e investigam sua acessibilidade e interação com vias e cruzamentos.

Para a construção desses modelos, faz-se necessária a obtenção de dados populacionais e socioeconômicos. No Brasil, o Censo Demográfico constitui uma das bases de dados mais relevantes para isso. Realizado pelo Instituto Brasileiro de Geografia e Estatística (IBGE), o Censo tem como principal objetivo a coleta sistemática de informações sobre a população e o território nacional. Apesar de seu papel essencial na formulação de políticas públicas e pesquisas científicas, desafios como restrições orçamentárias, mudanças metodológicas e dificuldades operacionais (Cano, Uchôas e Gallina, 2021) afetam a qualidade dos dados.

Além disso, a agregação de informações em grandes áreas (setores censitários) pode mascarar desigualdades locais, dificultando a identificação de padrões espaciais críticos. Com os avanços no geoprocessamento e a integração de bases de dados como o Cadastro Técnico Multifinalitário (CTM), tornou-se possível realizar análises mais detalhadas sobre a ocupação do solo e a infraestrutura urbana. No entanto, a granularidade dos dados continua sendo um

desafio para pesquisadores e gestores públicos. Diante disso, esta pesquisa combina diferentes fontes de dados e técnicas analíticas, como modelagem geoestatística e análise configuracional e de redes, para aprofundar a relação entre morfologia urbana e obesidade, além de discutir os desafios associados ao uso dos dados do Censo.

Metodologia

Este estudo investiga o impacto da agregação de dados censitários na análise de ambientes obesogênicos, avaliando como diferentes escalas influenciam a identificação de padrões espaciais relacionados à obesidade. Utilizando o bairro Santa Tereza, em Belo Horizonte, como estudo de caso, a pesquisa integra métodos geoespaciais e a epistemologia da complexidade para realizar uma análise crítica das relações entre planejamento urbano e saúde pública.

A pesquisa desenvolve um modelo computacional² em um Sistema de Informação Geográfica (SIG), gerando uma medida de obesogenicidade (IO)³ para quantificar o potencial de uma localidade em favorecer condições associadas à obesidade. Esse índice serve como uma ferramenta para identificar áreas de


risco e aprimorar abordagens no planejamento urbano e nas políticas de saúde. Além disso, a metodologia proposta oferece uma base para futuras pesquisas, permitindo ajustes nas variáveis e a incorporação de novos indicadores de obesogenicidade.

Coleta e preparação de dados

A coleta de dados envolveu fontes primárias e secundárias. A rede viária do bairro foi mapeada via OpenStreetMap® (Open Street Map Contributors, 2021), enquanto informações censitárias do IBGE, dados do CTM e da Companhia Energética de Minas Gerais (Cemig) complementaram a análise. Os dados passaram por limpeza e padronização para garantir interoperabilidade e compatibilidade com o software ArcGIS®/ArcMapTM (versão 10.8).

Além disso, uma auditoria de campo identificou e georreferenciou todos os estabelecimentos que comercializam, armazenam e produzem alimentos, como supermercados, padarias, açougues, comércios informais, entre outros (Faria, Souza e Mendes, 2024). Esses locais foram classificados por porte, tipo de consumo e localização, utilizando ferramentas como o Google My Maps. A Figura 2 sintetiza a estruturação dos dados no modelo.

Figura 2 – Síntese metodológica de análise espacial e estatística geoespacial



Fonte: Faria (2024).

Desenvolvimento do modelo

A pesquisa foi realizada no bairro Santa Tereza, reconhecido por sua relevância cultural e histórica, além de sua estrutura urbana marcada por ruas estreitas e moradias unifamiliares (características interioranas). O modelo analítico baseou-se na teoria da Sintaxe Espacial (Hillier, Yang e Turner, 2012; Hillier e Hanson, 1997) e na técnica de Road Centre Lines (RCL) (Krenz, 2017, 2018), classificando vias urbanas conforme sua permeabilidade ao movimento. Métricas sintáticas, como conectividade, profundidade, escolha e integração (Castro, 2016; Saboya, 2007; Turner, 2001, 2004, 2007), foram calculadas no software depthMapX (versão v0.8.0). Para modelar o

deslocamento pedonal, foram incorporados dados de impedância – *Network Dataset* –, que levaram em consideração fatores como a inclinação das ruas, a velocidade média de caminhada e a distância percorrida (Souza et al., 2016). Esse modelo foi implementado no software ArcGIS®/ArcMapTM (versão 10.8), refletindo as características de mobilidade no bairro.

Análise de rede: operações

Para a análise de rede, a metodologia adotada investiga a relação entre a centralidade por atração das edificações e as escolhas alimentares, analisando como a oferta de alimentos

contribui para a formação de espaços obesogênicos. Os estabelecimentos foram categorizados por porte – pequeno (+1), médio (+2) e grande (+3) –, servindo como base para a ponderação dos fatores atrativos. A tipologia alimentar e a modalidade de consumo foram incorporadas para relacionar forma urbana, distribuição espacial e padrões de consumo. Para operacionalizar a centralidade por atração das edificações, utilizou-se a ferramenta Urban Network Analysis (UNA) (Sevtsuk, 2010; Sevtsuk, Mekonnen e Kalvo, 2013; Sevtsuk e Mekonnen, 2012), identificando áreas com maior potencial de atrair pedestres.

Além disso, foi desenvolvido um modelo probabilístico para avaliar o impacto de diferentes cenários urbanos no risco de obesidade (Faria e Souza, 2024), com o intuito de testar diferentes formas de operacionalizar a obesogenicidade a partir de variáveis urbanas e socioeconômicas. Inspirado na equação de Drake,⁴ o modelo integra variáveis como densidade populacional (DHSO), renda média (RM), nível de escolaridade (EM), idade média dos residentes (IDADE), tipo de estabelecimento alimentar (TE), espaços para atividades físicas (DEP) e padrões de uso do solo (medidas sintáticas calculadas pelo depthMapX).

A medida de obesogenicidade (IO) foi inicialmente formulada como um produto simples dessas variáveis, sendo denominado por cenário simplista (IO₁). Para maior precisão, introduziu-se uma versão ponderada (IO₂), na qual cada fator recebeu um peso (w) específico com base na literatura. Apesar das restrições de tempo e orçamento, buscou-se representar de forma equilibrada as influências relativas das variáveis, distribuídas da seguinte maneira: densidade populacional (15%), renda média (25%),

idade (5%), educação média (10%), tipo de estabelecimento alimentar (30%) e presença de espaços para atividades físicas (15%). Estudos futuros são necessários para determinar com precisão esses pesos. Posteriormente, o modelo foi refinado com a inclusão da centralidade por alcance (*reach*) (Sevtsuk e Mekonnen, 2012), resultando na equação IO₃, que considera a acessibilidade espacial das variáveis analisadas.

$$(IO_1) = DHSO \times RM \times IDADE \times EM \times TE \times DEP$$

$$(IO_2) = (DHSO \times w_1) \times (RM \times w_2) \times (IDADE \times w_3) \times (EM \times w_4) \times (TE \times w_5) \times (DEP \times w_6)$$

$$(IO_3) = (DHSO \times w_1 \times reach_1) \times (RM \times w_2 \times reach_2) \times (IDADE \times w_3 \times reach_3) \times (EM \times w_4 \times reach_4) \times (TE \times w_5 \times reach_5) \times (DEP \times w_6 \times reach_6)$$

A escolha das variáveis que compõem o modelo foi fundamentada em evidências presentes na literatura sobre ambientes alimentares (Downs et al., 2020; Gálvez Espinoza et al., 2017; Mendes, Pessoa e Costa, 2022; Swinburn, Egger e Raza, 1999). Fatores como densidade populacional, renda, escolaridade, idade média, tipologia alimentar e presença de espaços para atividade física demonstram influência significativa sobre os comportamentos da população. No cenário IO₂, os pesos atribuídos a cada variável foram definidos de forma exploratória, com base na frequência e impacto desses fatores nos estudos analisados. Ainda que não se configurem como valores absolutos ou definitivos, esses pesos oferecem um ponto de partida para análises mais refinadas e podem ser ajustados conforme novos dados ou contextos analíticos. O Quadro 1 sintetiza o tratamento de cada variável e sua forma de incorporação ao modelo.

Quadro 1 – Tratamento das variáveis para incorporação ao modelo computacional

Variável	Operação
Densidade populacional (DHSO)	$DHSO = (\text{População da área censitária}) / (\text{Área da área censitária})$. Isso fornece a densidade populacional em cada unidade espacial.
Renda média (RM)	$RM = 1 / (\text{Renda Média})$, invertendo o valor para refletir a relação inversa com a obesogenicidade. Áreas com maior renda contribuem menos para a obesogenicidade.
Idade média dos residentes (IDADE)	$IDADE = ((V_{32} \times 0) + (\sum V_n \times \mu_n) + (V_{71} \times 97) + (V_{72} \times 100)) / \sum(V_n)$, onde V_n = população em cada faixa etária e μ_n = ponto médio de cada faixa etária.
Nível educacional dos residentes (EM)	Integração direta dos dados de anos de escolaridade, refletindo o status socioeconômico e seu impacto nos comportamentos de saúde.
Estabelecimentos alimentares (TE)	Classificação: Residencial = 1; Comercial = Pequeno ($0-30m^2$) = 2; Médio ($31-70m^2$) = 3; Grande ($>70m^2$) = 4. Aplicado usando VBScript no Calculador de Campos para converter categorias em valores numéricos.
Espaços para atividades físicas (DEP)	Valores de DEP ponderados pelo tempo de caminhada: 0–1 min = 0,50; 2 min = 0,55; 3 min = 0,60; 4 min = 0,65; 5 min = 0,70; 6 min = 0,75; 7 min = 0,80; 8 min = 0,85; 9 min = 0,90; 10 min = 0,95; 11+ min = 1,00. Calculado com curvas isocrônicas e automatizado com VBScript. Essa relação inversa garante que instalações mais próximas tenham um impacto positivo mais forte na redução da obesogenicidade.
Reach (centralidade por alcance dos edifícios)	Calculado pela ferramenta UNA (Sevtsuk, Mekonnen e Kalvo, 2013; Sevtsuk e Mekonnen, 2012) usando um raio de rede de 500 m para determinar o número de destinos alcançáveis, refletindo a acessibilidade espacial dentro do ambiente urbano.

Fonte: o autor, em 2025.

Embora a acessibilidade a serviços como supermercados, escolas ou centros comerciais seja tradicionalmente mensurada em faixas temporais mais amplas – como 5, 10 ou 15 minutos –, neste estudo optou-se por intervalos de 1 minuto. Essa escolha visa capturar com maior precisão as nuances do comportamento pedonal em microescala, especialmente em contextos urbanos heterogêneos e com presença de barreiras físicas e topográficas relevantes, como ocorre no bairro de Santa Tereza.

Essa decisão metodológica está inserida em uma abordagem exploratória e experimental baseada em cenários probabilísticos, que

busca representar com maior sensibilidade as complexas relações entre espaço e saúde. Apesar de simplificar as interações entre variáveis – ao assumir independência e efeitos multiplicativos –, o modelo constitui um ponto de partida para os estudos sobre ambientes obesogênicos no campo da arquitetura e urbanismo. Além de ser passível de replicação em outros contextos geográficos, essa estrutura permite ajustes e refinamentos futuros, como a testagem de diferentes recortes temporais e a inclusão de novas variáveis e relações, contribuindo para o avanço teórico-metodológico da área.

A aplicação das curvas gaussianas na análise da granulometria dos dados do censo

Na última etapa metodológica, foram construídas curvas de distribuição gaussiana normalizadas para as medidas de obesogenicidade (IO_1 , IO_2 e IO_3) e para a medida de centralidade por atração das edificações, com base em dados simulados que refletem sua distribuição espacial no bairro Santa Tereza. O processo seguiu três etapas principais:

1) Simulação e organização dos dados: os dados das medidas foram organizados em intervalos representativos, e os valores médios desses intervalos foram utilizados para a modelagem das distribuições. Todos os conjuntos de dados foram concatenados em único *DataFrame*, facilitando a manipulação e análise.

2) Cálculo das curvas gaussianas: utilizando a função *norm.pdf* da biblioteca *scipy.stats*, foram geradas curvas de densidade de

probabilidade normalizadas para cada medida. A normalização permitiu que as distribuições fossem comparadas diretamente, independentemente das diferenças de escala entre os índices.

3) Visualização e comparação das medidas: as curvas gaussianas foram plotadas com a biblioteca *matplotlib*, permitindo uma comparação gráfica das medidas. Foram utilizadas cores distintas para cada medida (azul para IO_1 , amarelo para IO_2 , vermelho para IO_3 e verde para a medida de gravidade).

Essa abordagem permitiu identificar padrões na obesogenicidade do bairro, destacando variações espaciais entre as medidas e sugerindo ajustes na granulometria dos dados. As curvas gaussianas indicaram tendências relevantes na distribuição das medidas, oferecendo *insights* sobre a escala mais adequada para análise. Os Quadros 2 e 3 apresentam os códigos Python utilizados para a construção dos gráficos de distribuição normal.

Quadro 2 – Código Python para construção do gráfico com as medidas IO₁, IO₂, IO₃

```

import matplotlib.pyplot as plt
import pandas as pd
import numpy as np
from scipy.stats import norm

# Dados simulados para as medidas IO1, IO2, IO3
io1_data = {
    'Intervalos': ["0,0029 - 0,0070", "0,0071 - 0,013", "0,014 - 0,017", "0,018 - 0,020", "0,021 - 0,023",
                  "0,024 - 0,026", "0,027 - 0,029", "0,030 - 0,036", "0,037 - 0,059", "0,060 - 0,19"],
    'Medidas': [0.005, 0.010, 0.0155, 0.019, 0.022, 0.025, 0.028, 0.033, 0.048, 0.125]}

io2_data = {
    'Intervalos': ["0,0029 - 0,0070", "0,0071 - 0,013", "0,014 - 0,017", "0,018 - 0,020", "0,021 - 0,023",
                  "0,024 - 0,026", "0,027 - 0,029", "0,030 - 0,036", "0,037 - 0,059", "0,060 - 0,19"],
    'Medidas': [0.0045, 0.0095, 0.0145, 0.0195, 0.0215, 0.0255, 0.0285, 0.0335, 0.046, 0.128]}

io3_data = {
    'Intervalos': ["0 - 0,005", "0,006 - 0,011", "0,012 - 0,017", "0,018 - 0,026", "0,027 - 0,035",
                  "0,036 - 0,045", "0,046 - 0,06", "0,061 - 0,08", "0,081 - 0,117", "0,118 - 0,196"],
    'Medidas': [0.0025, 0.0085, 0.0145, 0.022, 0.031, 0.0405, 0.053, 0.0705, 0.099, 0.157]}

# Convertendo para DataFrames
df_io1 = pd.DataFrame(io1_data)
df_io2 = pd.DataFrame(io2_data)
df_io3 = pd.DataFrame(io3_data)

# Gerando valores x para a curva gaussiana normalizada
x = np.linspace(-3, 3, 1000)

# Criando curvas gaussianas normalizadas
gaussian_io1 = norm.pdf(x, loc=0, scale=1) * max(df_io1['Medidas']) / max(norm.pdf(x, loc=0, scale=1))
gaussian_io2 = norm.pdf(x, loc=0, scale=1) * max(df_io2['Medidas']) / max(norm.pdf(x, loc=0, scale=1))
gaussian_io3 = norm.pdf(x, loc=0, scale=1) * max(df_io3['Medidas']) / max(norm.pdf(x, loc=0, scale=1))

# Plotando as curvas gaussianas normalizadas
plt.figure(figsize=(10, 6))

plt.plot(x, gaussian_io1, label='IO1 - Cenário Simplista', color='blue')
plt.plot(x, gaussian_io2, label='IO2 - Cenário Ponderado', color='yellow')
plt.plot(x, gaussian_io3, label='IO3 - Cenário Alcance Incorporado', color='red')

plt.title('Curvas de Distribuição Gaussiana Normalizada das Medidas IO1, IO2 e IO3')
plt.xlabel('Valores Normalizados')
plt.ylabel('Densidade de Probabilidade')
plt.legend()
plt.grid(True)
plt.tight_layout()

# Exibir gráfico
plt.show()

```

Fonte: o autor, em 2024.

Quadro 3 – Código Python para construção do gráfico com as medidas IO₁, IO₂, IO₃ e gravidade

(Continua)

```

import matplotlib.pyplot as plt
import pandas as pd
import numpy as np
from scipy.stats import norm

# Dados simulados para as medidas IO1, IO2, IO3
io1_data = {
    'Intervalos': ["0,0029 - 0,0070", "0,0071 - 0,013", "0,014 - 0,017", "0,018 - 0,020", "0,021 - 0,023", "0,024 - 0,026",
    "0,027 - 0,029", "0,030 - 0,036", "0,037 - 0,059", "0,060 - 0,19"],
    'Medidas': [0.005, 0.010, 0.0155, 0.019, 0.022, 0.025, 0.028, 0.033, 0.048, 0.125]
}

io2_data = {
    'Intervalos': ["0,0029 - 0,0070", "0,0071 - 0,013", "0,014 - 0,017", "0,018 - 0,020", "0,021 - 0,023", "0,024 - 0,026",
    "0,027 - 0,029", "0,030 - 0,036", "0,037 - 0,059", "0,060 - 0,19"],
    'Medidas': [0.0045, 0.0095, 0.0145, 0.0195, 0.0215, 0.0255, 0.0285, 0.0335, 0.046, 0.128]
}

io3_data = {
    'Intervalos': ["0 - 0,005", "0,006 - 0,011", "0,012 - 0,017", "0,018 - 0,026", "0,027 - 0,035", "0,036 - 0,045", "0,046 -
0,06", "0,061 - 0,08", "0,081 - 0,117", "0,118 - 0,196"],
    'Medidas': [0.0025, 0.0085, 0.0145, 0.022, 0.031, 0.0405, 0.053, 0.0705, 0.099, 0.157]
}

# Dados simulados para a Medida de Gravidade
gravidade_data = { 'Intervalos': ["0,000000 - 1,824365", "1,824366 - 4,372193", "4,372194 - 8,700763", "8,700764 -
17,602568", "17,602569 - 58,694008"],
    'Medidas': [0.912, 3.098, 6.536, 13.151, 38.148]
}

# Convertendo para DataFrames
df_io1 = pd.DataFrame(io1_data)
df_io2 = pd.DataFrame(io2_data)
df_io3 = pd.DataFrame(io3_data)
df_gravidade = pd.DataFrame(gravidade_data)

# Normalizing the data for better comparison across IO1, IO2, IO3, and Gravidade
# Concatenating all data into a single DataFrame
all_data = pd.concat([df_io1['Medidas'], df_io2['Medidas'], df_io3['Medidas'], df_gravidade['Medidas']])

# Calculating the overall mean and standard deviation
mean_all = all_data.mean()
std_all = all_data.std()

# Normalizing each dataset
df_io1['Medidas_Norm'] = (df_io1['Medidas'] - mean_all) / std_all
df_io2['Medidas_Norm'] = (df_io2['Medidas'] - mean_all) / std_all
df_io3['Medidas_Norm'] = (df_io3['Medidas'] - mean_all) / std_all
df_gravidade['Medidas_Norm'] = (df_gravidade['Medidas'] - mean_all) / std_all

# Gerando valores x para a curva gaussiana normalizada
x = np.linspace(-3, 3, 1000)

# Creating normalized Gaussian curves
gaussian_io1_norm = norm.pdf(x, loc=0, scale=1) * max(df_io1['Medidas_Norm']) / max(norm.pdf(x, loc=0,
scale=1))
gaussian_io2_norm = norm.pdf(x, loc=0, scale=1) * max(df_io2['Medidas_Norm']) / max(norm.pdf(x, loc=0,
scale=1))
gaussian_io3_norm = norm.pdf(x, loc=0, scale=1) * max(df_io3['Medidas_Norm']) / max(norm.pdf(x, loc=0,
scale=1))
gaussian_gravidade_norm = norm.pdf(x, loc=0, scale=1) * max(df_gravidade['Medidas_Norm']) / max(norm.pdf(x,
loc=0, scale=1)

```

Quadro 3 – Código Python para construção do gráfico com as medidas IO₁, IO₂, IO₃ e gravidade

(Conclusão)

```
# Plotting the normalized Gaussian curves
plt.figure(figsize=(10, 6))

plt.plot(x, gaussian_io1_norm, label='IO1 - Cenário Simplista', color='blue')
plt.plot(x, gaussian_io2_norm, label='IO2 - Cenário Ponderado', color='yellow')
plt.plot(x, gaussian_io3_norm, label='IO3 - Cenário Alcance Incorporado', color='red')
plt.plot(x, gaussian_gravidade_norm, label='Medida de Gravidade', color='green')

plt.title('Curvas de Distribuição Gaussiana Normalizada (Comparação Normalizada)')
plt.xlabel('Valores Normalizados')
plt.ylabel('Densidade de Probabilidade')
plt.legend()
plt.grid(True)
plt.tight_layout()

# Exibir gráfico
plt.show()
```

Fonte: o autor, em 2024.

Resultados e discussão


Esta seção apresenta e analisa os resultados da aplicação do modelo computacional de mensuração da obesogenicidade. São exibidos os mapas das diferentes operacionalizações (centralidade por atração das edificações e cenários de obesogenicidade – medidas IO₁, IO₂ e IO₃), revelando padrões espaciais. Discute-se a similaridade entre as medidas IO₁ e IO₂ por meio de um teste de correlação, além da análise das curvas de distribuição gaussiana, que auxiliam na compreensão da estrutura dos dados e sua relação com o ambiente construído. Por fim, os achados são contextualizados em relação aos objetivos deste estudo, destacando implicações metodológicas e urbanísticas.

Resultados gerais

O resultado da centralidade por atração das edificações, calculado com a ferramenta UNA, sobreposta com a representação da combinação da medida de integração e a relação de escolha (INCH)⁵ das vias, calculada com o software depthMapX, é apresentado na Figura 3. Essa visualização integrada permite evidenciar como os padrões de uso do solo se articulam com a configuração espacial do sistema viário, influenciando o fluxo urbano e os potenciais de acessibilidade em diferentes trechos da malha urbana.

As áreas de menor atratividade (tons frios) concentram-se nas bordas do bairro, enquanto as de maior atração (tons quentes) estão

Figura 3 – Centralidade dos edifícios por atração sobreposta com a representação da combinação da medida de integração + relação de escolha (INCH) das vias




Fonte: o autor, em 2024.

em eixos viários principais e regiões centrais. Esse padrão, alinhado à Teoria do Movimento Natural (Hillier et al., 1993), mostra que vias mais integradas atraem maior fluxo de pedestres e atividades comerciais. A distribuição evidenciada sugere que a configuração urbana impacta a concentração de estabelecimentos alimentícios, predominantemente de alimentos ultraprocessados, nas áreas mais acessíveis. Esse padrão reforça a ideia de que a acessibilidade espacial pode desempenhar um papel significativo na

formação de hábitos alimentares, destacando a necessidade de políticas públicas que incentivem a diversificação da oferta alimentar, com ênfase em produtos in natura.

A Figura 4 apresenta o mapa do cenário simplista (IO+), que exhibe a distribuição espacial da obesogenidade no bairro Santa Tereza, destacando a influência combinada de fatores como densidade populacional, renda, idade, educação, oferta de alimentos e espaços para atividade física.

Figura 4 – Mapa da distribuição da medida de obesogenicidade resultante da operacionalização do cenário simplista (IO_1) no bairro Santa Tereza, classificada pelo método Natural Breaks (Jenks)




Fonte: o autor, em 2024.

As áreas em vermelho e laranja, com maiores medidas IO_1 , estão concentradas nas partes norte e oeste do bairro, especialmente na Vila São Vicente e nos arredores de um condomínio fechado, onde a densificação urbana é mais intensa. Já as áreas em azul e verde, com menor medida IO_1 , correspondem a zonas de baixa densidade populacional. Esse padrão sugere que áreas mais conectadas e densas tendem a atrair uma maior variabilidade de estabelecimentos, incluindo opções menos saudáveis, contribuindo para a formação de ambientes obesogênicos. A distribuição de IO_1 é difusa e gradual, evidenciando que a obesogenicidade não se restringe a pontos isolados, mas é um fenômeno dinâmico relacionado à

estrutura urbana e comportamento social, o que reforça a necessidade de um planejamento urbano que considere essas dinâmicas para mitigar seus impactos

O cenário ponderado (IO_2) foi operacionalizado atribuindo pesos a variáveis fundamentados na literatura. A análise visual do mapa resultante (Figura 5) revela semelhanças com o mapa de IO_1 , levantando hipóteses sobre a normalização dos dados. Um teste de sensibilidade foi realizado para investigar se a normalização – método de Natural Breaks, Jenks – estava mascarando as diferenças entre as medidas. Após comparar a normalização com o método quantil amostral, não se observaram divergências significativas.

Figura 5 – Mapa da distribuição da medida de obesogenicidade resultante da operacionalização do cenário ponderado (IO₂) no bairro Santa Tereza, classificada pelo método Natural Breaks (Jenks)



Fonte: o autor, em 2024.

Com a hipótese sobre normalização descartada, investigou-se como as diferenças matemáticas entre IO₁ e IO₂ poderiam ser sutis ou imperceptíveis visualmente, mesmo com pesos distintos. Um teste de correlação entre as medidas IO₁ e IO₂, realizado com a função “CORREL” no Excel® (Microsoft®, 2024) (Figura 6), revelou uma correlação positiva perfeita (valor 1), indicando que as variações espaciais das duas medidas são exatamente proporcionais. Ou seja, onde IO₁ aumenta, IO₂ também aumenta na mesma proporção, e onde IO₁ diminui, IO₂ segue o mesmo padrão.

Esse resultado sugere que a agregação dos dados censitários, que utiliza unidades espaciais grandes, pode ter “achatado” as variações nas variáveis. Essa uniformidade nas representações visuais e na correlação pode ser um reflexo da incapacidade dos dados agregados em diferenciar, de forma eficaz, as pequenas variações espaciais que poderiam existir caso os dados fossem coletados ou analisados em uma escala mais fina. A agregação de dados, portanto, limita a capacidade de uma análise mais precisa e detalhada, ocultando disparidades ou padrões locais que são

Figura 6 – Ilustração do teste de correlação das medidas IO₁ e IO₂ no software Excel®

	A	B	C	D	E	F
1	IO1	IO2	IO3			
2	0,001302688	3,41956E-05	22401882419			
3	0,000937735	2,46155E-05	1,08032E+11			
4	0,002298671	6,03401E-05	14257134013		= CORREL(A2:A4494; B2:B4494)	
5	0,002298671	6,03401E-05	14257134013			
6	0,002475492	6,49817E-05	12747736113			
7	0,002475492	6,49817E-05	12747736113			
8	0,002652313	6,96232E-05	36712795774			
9	0,002829134	7,42648E-05	50227989132			
10	0,002298671	6,03401E-05	50521783429			
11	0,002643467	6,9391E-05	1,5139E+11			
12	0,002475492	6,49817E-05	45846310515			

Fonte: captura de tela, editada pelo autor, em 2024.


essenciais para a compreensão das interações dos fenômenos urbanos, o que pode gerar conclusões limitadas.

No cenário com alcance incorporado (IO₃), a introdução da centralidade por alcance foi considerada, sinalizando uma distribuição espacial heterogênea de obesogenicidade (Figura 7). As áreas com maior alcance, indicadas por cores quentes, concentram-se nas regiões centrais e norte do bairro Santa Tereza, caracterizadas por aspectos históricos e culturais. A concentração de altos valores de IO₃ ao longo dos principais corredores viários do bairro, com maior densidade de estabelecimentos, reforça que vias mais integradas atraem atividades comerciais, influenciando diretamente o ambiente obesogênico. Para mais, pode-se dizer que os corredores viários principais atuam como catalisadores no desenvolvimento de ambientes de distribuição e consumo de alimentos.

Ao comparar com os cenários IO₁ e IO₂, a introdução da centralidade por alcance no modelo expõe nuances mais complexas, com regiões que antes apresentavam valores moderados de obesogenicidade agora exibindo valores mais altos. Isso indica que a relação de conectividade espacial e a relação entre edificações vizinhas têm um papel significativo na formação do ambiente obesogênico. Além disso, a medida reach mostra como a concentração de edificações em áreas densas e conectadas aumenta o potencial obesogênico, demonstrando a interação entre fatores ambientais, sociais e de infraestrutura no desenvolvimento de espaços propensos à obesidade.

A análise dos dados no bairro Santa Tereza revela como diferentes fatores socioeconômicos e urbanos moldam a obesogenicidade local. Áreas com alta densidade populacional, baixa renda e escolaridade apresentam índices

Figura 7 – Mapa da distribuição da medida de obesogenicidade resultante da operacionalização do cenário com alcance incorporado (IO₃) no bairro Santa Tereza, classificada pelo método Natural Breaks (Jenks)



mais elevados de obesogenicidade (IO₁ e IO₂), enquanto regiões com melhor acesso a espaços para atividades físicas e maior nível educacional mostram valores mais baixos. A sobreposição das variáveis geoespaciais com as medidas de obesogenicidade permite identificar esses padrões, destacando a influência direta do ambiente construído na formação de espaços obesogênicos.

Entretanto, a utilização de dados agregados, como os do Censo, tende a suavizar variações mais finas e locais, dificultando a

percepção de pequenas diferenças espaciais que poderiam ser relevantes. A combinação de dados em unidades maiores pode mascarar nuances importantes, tornando os resultados menos sensíveis às características específicas de escalas menores. No cenário IO₃, que leva em conta a acessibilidade a espaços para atividades físicas, essa suavização se torna ainda mais evidente, já que a proximidade a esses locais pode compensar parcialmente os impactos negativos da densidade populacional e das condições socioeconômicas desfavoráveis. Isso


revela a complexidade das interações entre os fatores urbanos e sociais, sugerindo que o planejamento urbano deve ser sensível a essas variabilidades para promover ambientes mais saudáveis e resilientes.

Avaliando as curvas de distribuição

A curva de distribuição gaussiana, ou normal, é uma representação gráfica que ilustra a distribuição de dados contínuos, com a maior concentração de valores em torno da média e uma diminuição da probabilidade de valores

extremos à medida que se afastam dessa média (Batanero, Tauber e Sánchez, 2001; Bittencourt e Viali, 2006). No contexto das medidas de obesogenicidade (IO_1 , IO_2 e IO_3) para o bairro Santa Tereza, a curva normalizada foi utilizada para comparar a variação e concentração dos índices calculados em cada cenário, permitindo observar como diferentes abordagens de ponderação e variáveis espaciais impactam a obesogenicidade. A normalização permite que as distribuições sejam comparáveis, apesar das diferenças nos valores absolutos entre os cenários. A Figura 8 apresenta curvas de distribuição gaussiana normalizadas das medidas IO_1 , IO_2 e IO_3 .

Figura 8 – Curvas de distribuição gaussiana normalizadas das medidas IO_1 , IO_2 e IO_3




Fonte: o autor, em 2024.

Já a análise comparativa das curvas normalizadas das medidas de obesogenicidade (IO_1 , IO_2 , IO_3) e da medida da centralidade por atração dos edifícios (Figura 9) exprime diferenças fundamentais na forma como essas metodologias capturam a estrutura espacial do bairro. Por um lado, a curva da medida de gravidade apresenta alta concentração ao redor do valor central, indicando que poucas áreas se destacam como polos, enquanto a maioria mantém valores moderados. Essa característica sugere que a metodologia de centralidade por atração é eficaz para identificar focos urbanos bem definidos, sendo especialmente útil para o planejamento territorial. No entanto, essa concentração também implica uma menor sensibilidade a variações espaciais mais sutis, o que pode limitar sua aplicabilidade em estudos voltados para fatores difusos, como a obesogenicidade.

Por outro lado, as curvas das medidas de obesogenicidade mostram maior dispersão, refletindo a influência de múltiplas variáveis espaciais e sociais. Essa dispersão indica que as medidas IO são mais sensíveis a variações no ambiente urbano, proporcionando uma visão detalhada da distribuição dos fatores de risco à obesidade. Além disso, a ausência de uma distribuição perfeitamente gaussiana sugere que os fenômenos relacionados à obesogenicidade operam em múltiplos estados metaestáveis, capturando particularidades que a metodologia de centralidade por atração das edificações não demonstra. Assim, enquanto a medida de gravidade destaca áreas de atração central, os índices de obesogenicidade oferecem uma leitura mais difusa e complexa do espaço urbano, tornando as abordagens complementares na análise da dinâmica territorial e da saúde pública.

Figura 9 – Curvas de distribuição gaussiana normalizadas das medidas IO_1 , IO_2 , IO_3 e gravidade



Fonte: o autor, 2024.

No entanto, a granularidade dos dados censitários impõe limitações a essa análise, pois a agregação das informações por setor censitário suaviza variações espaciais mais finas. No cenário simplista (IO_1), essa característica se traduz em uma distribuição mais homogênea dos índices, onde as diferenças espaciais parecem menos acentuadas. À medida que os cenários evoluem, incorporando ponderações (IO_2) e fatores como acessibilidade (IO_3), as variações se tornam mais evidentes, mas ainda estão sujeitas à escala dos dados utilizados. Como os setores censitários reúnem um conjunto heterogêneo de indivíduos em uma única unidade estatística, há o risco de médias que mascaram desigualdades internas do território. Isso significa que microvariações espaciais, essenciais para a compreensão dos padrões de obesogenicidade, podem ser diluídas, reduzindo a percepção de contrastes significativos entre diferentes áreas. Embora a normalização das curvas permita comparações entre metodologias, os próprios limites da escala censitária indicam a necessidade de abordagens complementares – como o uso de dados em resoluções mais finas ou métodos que minimizem os efeitos da agregação –, garantindo uma análise mais fiel da relação entre o ambiente urbano e a obesogenicidade.

Considerações finais

A análise desenvolvida ao longo deste estudo revelou limitações intrínsecas à utilização de dados agregados, particularmente no que tange à preservação de nuances e heterogeneidades sociais. A capacidade de sintetizar grandes volumes de informação por meio da agregação estatística é, sem dúvida, uma ferramenta poderosa para formulação de políticas e análise de tendências. No entanto, esse mesmo processo pode

inadvertidamente perpetuar desigualdades estruturais ao mascarar disparidades críticas entre subgrupos populacionais e territórios. A diluição das disparidades socioeconômicas e territoriais dentro de dados agregados não é um efeito colateral trivial, mas um fenômeno que pode reforçar narrativas enviesadas e perpetuar assimetrias preexistentes. Esse efeito é particularmente crítico em contextos urbanos, onde as desigualdades são dinâmicas e espacialmente segmentadas. Assim, a exclusão de camadas mais detalhadas de informação pode resultar em diagnósticos imprecisos e políticas ineficazes, que não contemplam as especificidades locais.

Diante disso, este estudo reforça a necessidade de metodologias híbridas que combinem análises quantitativas e qualitativas, incorporando abordagens mais granulares para mitigar os vieses da agregação. O uso de microdados, técnicas de análise espacial e a inclusão de variáveis interseccionais podem fornecer uma visão mais abrangente e justa dos fenômenos sociais. Portanto, o aprimoramento das técnicas de análise de dados agregados e a incorporação de novas metodologias são passos fundamentais para garantir diagnósticos mais precisos e políticas públicas mais eficazes e equitativas. O desafio é desenvolver abordagens que conciliem a necessidade de síntese estatística com a preservação da diversidade e das especificidades das populações analisadas.

Em relação ao modelo proposto nesta pesquisa, ele se afasta de uma visão determinista e busca, na complexidade da cidade, uma compreensão mais flexível e aberta das dinâmicas urbanas. Ao contrário de prever padrões ou comportamentos futuros, o modelo revela as interações complexas entre espaço e sociedade, desafiando a lógica de previsões absolutas e proporcionando uma ferramenta para observar e interpretar a cidade em sua riqueza de possibilidades e incertezas. Dessa forma, o

modelo não busca apenas iluminar aspectos da realidade urbana, mas também se posiciona como um convite à exploração contínua, reconhecendo as limitações do conhecimento e abraçando a complexidade inerente aos fenômenos urbanos. Ele não oferece respostas definitivas,

mas proporciona uma perspectiva mais profunda sobre a relação entre espaço e saúde, sugerindo uma abordagem integrada que considere tanto as especificidades espaciais quanto as interações sociais que moldam os ambientes urbanos e suas dinâmicas.

[1] <https://orcid.org/0000-0002-1568-4498>

Universidade Federal de Minas Gerais, Escola de Arquitetura, Programa de Pós-Graduação em Arquitetura e Urbanismo. Belo Horizonte, MG/Brasil.
guscamfar@live.com

Notas

- (1) Para saber mais sobre as métricas e relações da Sintaxe Espacial, consulte: Hillier, 2008; Hillier et al., 1993; Hillier, Yang e Turner, 2012; Hillier e Hanson, 1997.
- (2) O modelo é resultando da tese de doutorado Modelo de espaços obesogênicos em ambientes urbanos, defendida em 2024 pelo Programa de Pós-Graduação em Arquitetura e Urbanismo da Universidade Federal de Minas Gerais. Para saber mais sobre a construção do modelo, ver Faria (2024).
- (3) Sempre que o trabalho fizer menção ao índice ou à medida de obesogenicidade (IO), estará se referindo ao índice relativo do potencial de uma determinada localidade em promover comportamentos e condições que favorecem o desenvolvimento de quadros clínicos da obesidade.
- (4) A equação de Drake é usada para estimar o número de civilizações extraterrestres na Via Láctea (Ciência Todo Dia, 2021).
- (5) O INCH, métrica da Sintaxe Espacial, combina as medidas de integração e escolha para avaliar a acessibilidade e o potencial de movimento em uma rede. A medida de integração indica o quão conectado um elemento está em relação ao restante, enquanto a relação de escolha representa a frequência com que uma via pode ser utilizada como caminho mais curto entre diferentes pontos.

Referências

- BATANERO, C.; TAUBER, L.; SÁNCHEZ, V. (2001). Significado y comprensión de la distribución normal en un curso introductorio de análisis de datos. *Cuadrante*, v. 10, n. 1, pp. 59-92.
- BITTENCOURT, H. R.; VIALI, L. (2006). Contribuições para o ensino da distribuição normal ou curva de Gauss em cursos de Graduação. In: III SEMINÁRIO INTERNACIONAL DE PESQUISA EM EDUCAÇÃO MATEMÁTICA.
- CANO, E. C.; UCHÔAS, A. A.; GALLINA, F. (2021). Os desafios do IBGE e a realização do Censo Demográfico 2022. *Geofronter*, n. 7. DOI: <https://doi.org/10.61389/geofronter.v7.6553>.
- CASTRO, A. (2016). *Sintaxe espacial e a análise angular de segmentos, parte 3: calculando medidas sintáticas*. Disponível em: <https://aredeurbana.com.br/2016/06/26/sintaxe-espacial-e-a-analise-angular-de-segmentos-parte-3-calculando-medidas-sintaticas/>. Acesso em: 10 ago 2021.
- CIÊNCIA TODO DIA (2021). A Equação de Drake: existe vida fora da Terra? *YouTube*. Disponível em: <https://www.youtube.com/watch?v=wbqlz0znhrq>. Acesso em: 10 jul 2022.
- DOWNS, S. M.; AHMED, S.; FANZO, J.; HERFORTH, A. (2020). Food environment typology: advancing an environments toward sustainable diets. *Foods*, v. 9, n. 4, p. 532. DOI: <https://doi.org/10.3390/foods9040532>.
- EGGER, G.; SWINBURN, B. (1997). An “ecological” approach to the obesity pandemic. *BMJ*, v. 315, n. 7106, pp. 477-480. DOI: <https://doi.org/10.1136/bmj.315.7106.477>.
- FARIA, G. H. C. de; SOUZA, R. C. F. de (2024). Desenvolvimento de um índice para estimar a distribuição de espaços obesogênicos em ambientes urbanos: uma abordagem inspirada na Equação de Drake. *Anais. Seminário Internacional PROJETAR: Projetar para quem? Projetar para quê? Projetar como?* DOI: <https://doi.org/10.29327/projetar2023.657636>.
- FARIA, G. H. C. de; SOUZA, R. C. F. de; MENDES, L. L. (2024). Modelos configuracionais para a avaliação da obesogenicidade em entornos urbanos. *Gestão & Tecnologia de Projetos*, v. 19, n. 1, pp. 5-28. DOI: <https://doi.org/10.11606/gtp.v19i1.209856>.
- FARIA, G. H. C. de F. (2024). *Modelo de espaços obesogênicos em ambientes urbanos*. Tese de doutorado. Belo Horizonte, Universidade Federal de Minas Gerais.
- GÁLVEZ ESPINOZA, P.; EGAÑA, D.; MASFERRER, D.; CERDA, R. (2017). Propuesta de un modelo conceptual para el estudio de los ambientes alimentarios en Chile. *Revista Panamericana de Salud Pública*, pp. 1-9. DOI: <https://doi.org/10.26633/rpsp.2017.169>.
- HAYNES, K. E.; FOTHERINGHAM, A. S. (1985). *Gravity and Spatial Interaction Models* (Web Book). WVU Research Repository.
- HILLIER, B. (2007). *Space is the machine: a configurational theory of architecture* (Edição eletrônica). UCL Space Syntax.
- _____. (2008). *Using DepthMap for urban analysis: a simple guide on what to do once you have an analysable map in the system*. The Bartlett School of Graduate Studies.
- HILLIER, B.; HANSON, J. (1984). *The social logic of space*. University Press. <https://doi.org/10.1017/CBO9780511597237>.
- _____. (1997). The reasoning art: or, the need for an analytical theory of architecture. 1st International Space Syntax Symposium, 01.1-01.5.

- HILLIER, B.; PENN, A.; HANSON, J.; GRAJEWSKI, T.; XU, J. (1993). Natural movement: or, configuration and attraction in urban pedestrian movement. *Environment and Planning B: Planning and Design*, v. 20, n. 1, pp. 29-66. DOI: <https://doi.org/10.1068/b2000029>.
- HILLIER, B.; YANG, T.; TURNER, A. (2012). Normalising least angle choice in Depthmap and how it opens up new perspectives on the global and local analysis of city space. *The Journal of Space Syntax*, v. 3, n. 2, pp. 155-193.
- JENSEN-BUTLER, C. (1972). Gravity models as planning tools: a review of theoretical and operational problems. *Geografiska Annaler. Series B, Human Geography*, v. 54, n. 1, p. 68. DOI: <https://doi.org/10.2307/490586>.
- KRENZ, K. (2017). Employing volunteered geographic information in space syntax analysis. 11th International Space Syntax Symposium, v. 150, n. 26, pp. 1-150.
- _____. (2018). *Network centralities in polycentric urban regions: methods for the measurement of spatial metrics*. Tese de doutorado. Bartlett Faculty of the Built Environment.
- MATOZINHOS, F. P.; GOMES, C. S.; GARDONE, D. S.; CARMO, A. S. do; SANTOS, L. C. dos; MENDES, L. L.; PESSOA, M. C. (2022). "Ambiente obesogênico". In: MENDES, L. L.; PESSOA, M. C.; COSTA, B. V. de L. (org.) *Ambiente alimentar: saúde e nutrição*. Rio de Janeiro, Rubio, pp. 135-146.
- MICROSOFT® (2024). Microsoft Excel (Versão 2407 Build 16.0.17830.20166).
- NETTO, V. (2016). 'What is space syntax not?' Reflections on space syntax as sociospatial theory. *Urban Design International*, v. 21, n. 1, pp. 25-40. DOI: <https://doi.org/10.1057/udi.2015.21>.
- OPEN STREET MAP CONTRIBUTORS (2021). Open Street Map database [PostgreSQL via API] (Available under the Open Database Licence from: openstreetmap.org). OpenStreetMap Foundation. Disponível em: <https://planet.openstreetmap.org>. Acesso em: 20 jul 2022.
- SABOYA, R. (2007). *Sintaxe espacial*. Disponível em: <https://urbanidades.arq.br/2007/09/03/sintaxe-espacial/>. Acesso em: 10 ago 2021.
- SEVTSUK, A. (2010). *Path and Place: A Study of Urban Geometry and Retail Activity in Cambridge and Somerville, MA*. Tese de doutorado. Massachusetts, Institute of Technology.
- _____. (2014). "Analysis and Planning of Urban Networks". In: Encyclopedia of Social Network Analysis and Mining. Nova York, Springer, pp. 25-37. DOI: https://doi.org/10.1007/978-1-4614-6170-8_43.
- SEVTSUK, A.; MEKONNEN, M. (2012). Urban network analysis. A new toolbox for ArcGIS. *Revue internationale de géomatique*, v. 22, n. 2, pp. 287-305. DOI: <https://doi.org/10.3166/rig.22.287-305>.
- SEVTSUK, A.; MEKONNEN, M.; KALVO, R. (2013). Urban Network analysis: toolbox for ArcGIS 10 / 10.1 / 10.2.
- SOUZA, R. C. F. de; OLIVEIRA, V. B. de; PEREIRA, D. B.; COSTA, H. S. de M.; CAIAFFA, W. T. (2016). Viver próximo à saúde em Belo Horizonte. *Cadernos Metrópole*. São Paulo, v. 18, n. 36, pp. 326-344. DOI: <https://doi.org/10.1590/2236-9996.2016-3601>.
- SWINBURN, B.; EGGER, G.; RAZA, F. (1999). Dissecting obesogenic environments: The development and application of a framework for identifying and prioritizing environmental interventions for obesity. *Preventive Medicine*, v. 29, n. 6 I, pp. 563-570. DOI: <https://doi.org/10.1006/pmed.1999.0585>.

TURNER, A. (2001). Depthmap: A Program to Perform Visibility Graph Analysis. In: 3rd INTERNATIONAL SYMPOSIUM ON SPACE SYNTAX, v. 30, n. 11, pp. 1-30,.

_____ (2004). *Depthmap 4: A Researcher's Handbook*. Bartlett School of Graduate Studies.

_____ (2007). From Axial to road-centre lines: a new representation for space syntax and a new model of route choice for transport network analysis. *Environment and Planning B: Planning and Design*, v. 34, n. 3, pp. 539-555. DOI: <https://doi.org/10.1068/b32067>

Contribuição de autoria

Gustavo Henrique Campos de Faria: análise formal; conceitualização; investigação; metodologia; redação; visualização.

Declaração de Disponibilidade de Dados

O conjunto de dados de apoio aos resultados deste estudo não está disponível ao público.

Editores: Lucia Bógus e Luiz César de Queiroz Ribeiro

Organizadores deste número: Suzana Pasternak e Luís Felipe Aires Magalhães

Texto recebido em 28/mar/2025

Texto aprovado em 30/jul/2025

