

SEGMENTAÇÃO SEMÂNTICA PARA IDENTIFICAÇÃO DE CENAS URBANAS QUE SÃO INCENTIVOS OU BARREIRAS À CAMINHADA

Shanna Trichês Lucchesi

Douglas Zechin

Ana Margarita Larranaga

Helena Beatriz Bettella Cybis

Laboratório de Sistemas de Transportes (LASTRAN)

João António de Abreu e Silva

Universidade de Lisboa

Instituto Superior Técnico

RESUMO

As características do ambiente urbano ao nível da rua afetam o comportamento dos pedestres. No entanto, identificar dados de microescala urbana pode ser desafiador. O recente desenvolvimento de técnicas de reconhecimento de imagem está ajudando pesquisadores a coletar dados de forma rápida e em larga escala. Por isso, este estudo busca testar a aplicação de um algoritmo de segmentação semântica para representar cenas urbanas na cidade de São Paulo. Combinando classes pré-determinadas do algoritmo buscamos compreender que ambientes podem ser identificados como um incentivador ou inibidor aos deslocamentos a pé. Foi utilizada uma técnica de multivariada confirmatória para identificar o impacto das cenas urbanas na frequência de caminhada. As percepções da caminhabilidade do bairro foram modeladas mediando este efeito. Vias dedicadas aos carros e rodovias urbanas foram consideradas as principais barreira à caminhada, enquanto áreas iluminadas e próximas de rotas de transporte coletivo foram consideradas incentivadoras ao caminhar.

ABSTRACT

The built environment characteristics deeply influence pedestrians' behaviour. However, identify microscale-built environment data is challenging and time-consuming. The development of image recognition algorithms is helping researchers to collect data quickly on a large scale. Therefore, this study aims to test the application of semantic segmentation algorithm to represent urban scenes in the city of São Paulo. Combining the predetermined categories of the algorithms helps to understand which type of environment represents barriers or incentives to walking. We used a confirmatory multivariate technique to identify the impacts of the built environment characteristics on the walking behaviour mediate by the walkability perceptions. Car-oriented areas and urban highways considered detrimental to the walkability perception and consequently to the walking frequency, while areas close to public transportation routes with the presence of light are those consider more friendly for pedestrian and encourage walking.

1. INTRODUÇÃO

Bairros que incentivam à caminhada tem um papel central em promover comunidades sustentáveis. Incentivos à caminhabilidade vem sendo amplamente documentados na literatura científica quanto aos seus impactos no meio ambiente, na segurança pública, nas interações sociais, no bem-estar, no nível de atividade física e nos benefícios econômicos derivados deste incentivo (Brown *et al.*, 2009; Jun e Hur, 2015; Lucchesi, Larranaga, Bettella Cybis, *et al.*, 2020; Lucchesi, Larranaga, Ochoa, *et al.*, 2020; Marshall *et al.*, 2009; van den Berg *et al.*, 2017). Por muitos anos, pesquisadores tem buscado entender que componentes do ambiente urbano construído atuam no aumento da frequência de caminhada. Independente do agrupamento teórico utilizado para descrever as características de um bairro caminhável - os "7Ds" (Ewing e Cervero, 2010), "S+5 Ds" (Kang, 2018), "7Cs" (Moura *et al.*, 2017), ou "As" (Handy, 2018) – é consenso que os indivíduos preferem caminhar em ambientes agradáveis, com espaço adequado para estar ou passar, onde as pessoas podem encontrar e ver outras pessoas. Essas características são tradicionalmente descritas usando variáveis que representam densidade, uso do solo misto, conectividade das vias, características dos passeios, distância dos pontos de embarque e desembarque, entre outras.

No entanto, não são somente as características objetivas do ambiente construído que impactam a disposição a caminhar, mas também como elas são percebidas pelos indivíduos em uma dimensão mais subjetiva do ambiente (Ma e Cao, 2019; Ma e Dill, 2017). Sendo assim, o processo de tomada de decisão é baseado em experiências prévias e afetado pelas condições socioeconômicas dos pedestres. Esse tom pessoal altera como diferentes indivíduos reagem ao mesmo estímulo. Ainda, avaliar percepções é ainda mais crítico em estudos sobre caminhabilidade visto que pedestres são mais expostos às influências do ambiente do que outros modos (Ma e Cao, 2019). Entender como as percepções sobre o ambiente afetam comportamento pode elucidar que tipo de características são mais percebidas como amigáveis aos deslocamentos a pé e quais desestimulam o caminhar.

Embora a maioria dos estudos que abordam caminhabilidade foque nos atributos que contribuem para aumentar a percepção da mobilidade, entender as barreiras para caminhar pode ser mais eficaz na mudança de percepções e, conseqüentemente, do comportamento de viagem. Além das características individuais que podem influenciar a vontade de caminhar (por exemplo, idade, gênero, condições físicas etc.) (Clark e Scott, 2016), o ambiente construído também impõe barreiras para os pedestres. Vias amplas (Cisneros, 2015), com falta de conectividade (Larranaga *et al.*, 2018; Wang *et al.*, 2016), más condições das calçadas (Ferrer *et al.*, 2015; Larranaga *et al.*, 2018) e um ambiente pouco atraente ou voltado para carros (Bozovic *et al.*, 2021; Ferrer *et al.*, 2015; Larranaga *et al.*, 2018) são algumas das características da infraestrutura das cidades que prejudicam a caminhada. Nos países em desenvolvimento, como o Brasil, a segurança pública também pode ser uma barreira percebida para modos de transporte não motorizados (Forsyth, 2015; Larranaga *et al.*, 2018; Lucchesi *et al.*, 2020).

No entanto, a percepção dos pedestres das barreiras do ambiente construído é sensível à experiência de caminhada no nível da rua. No entanto, só recentemente os pesquisadores começaram a considerar dados em microescala para avaliar caminhabilidade (Anapakula e Eranki, 2021; Bivina *et al.*, 2020; Kim *et al.*, 2014; Larranaga *et al.*, 2018). Uma revisão de literatura considerando os últimos 10 anos de publicações sobre caminhabilidade conduzido por Arellana *et al.* (Arellana *et al.*, 2019) em 2020 mostrou que somente 14% dos estudos incluiu dados em microescala para calcular indicadores de caminhabilidade. Dados não disponíveis, incapacidade de processar uma quantidade grande de dados ou falta de padrão são alguns problemas operacionais com dados espaciais em microescala (Arellana *et al.*, 2019; Reid Ewing *et al.*, 2013). Além disso, a coleta de dados em microescala pode ser um desafio, pois exige uma quantidade significativa de tempo e recursos.

Durante a última década, novas formas de obter dados de alta qualidade sobre a infraestrutura das cidades surgiram devido à disponibilidade de imagens 360° de alta resolução. Um exemplo de uma fonte abrangente de imagens no nível da rua é o banco de dados *Google Street View*. As imagens do *Google Street View* têm um alto potencial de aplicação em modelos de pedestres, pois permitem a coleta contínua de informações na rede avaliada e representam a experiência do nível dos olhos, tendo uma grande semelhança com o que os pedestres veem nas ruas (Anderson, 2017; Yin *et al.*, 2015). No entanto, a decodificação de imagens da vida real em atributos de ambiente integrado exige algoritmos de reconhecimento de imagem alinhados com tecnologias de aprendizado de máquina. Os algoritmos mais utilizados para classificar imagens do ambiente construído aplica o método da segmentação semântica, onde os elementos identificados precisam ser categorizados em diferentes classes semânticas pré-determinadas (Badrinarayanan *et al.*, 2014; Chen *et al.*, 2018; Ilarri *et al.*, 2015). Pesquisadores estão

começando a aplicar estes dados em estudos para avaliar o ambiente urbano. Poucos estudos focam em identificar ‘ruas vivas’ (Li et al., 2021) e caminhabilidade (X. Ma et al., 2021; Nagata et al., 2020). Apesar disso, ainda faltam conhecimentos relativos a como esses dados secundários podem auxiliar a entender a percepção dos usuários sobre barreiras à caminhada.

Esse artigo, portanto, persegue três objetivos. Primeiro, busca avaliar a aplicação de técnicas de reconhecimento de imagem para produção de dados secundários para modelos de econométricos de percepção de caminhabilidade. Segundo analisar como estes dados podem auxiliar a identificar inibidores e incentivos através da análise de cenas urbanas. Finalmente, identificar como as combinações dos atributos do ambiente urbano identificados pelos algoritmos no entorno da residência impactam na percepção da caminhabilidade e no comportamento de viagens. Neste artigo foram utilizados modelos de equações estruturais como técnica econométrica confirmatória para avaliar a combinação dos atributos em três bairros da cidade de São Paulo. Este estudo contribui para a literatura existente preenchendo a lacuna de estudos que analisam barreiras à caminhada usando dados em microescala e ao testar fontes de dados secundários que podem contribuir para uma imensa gama de estudos na área da mobilidade.

2. DADOS

Duas fontes de dados foram utilizadas: (i) uma pesquisa domiciliar como fonte de dados para os indicadores da percepção de caminhabilidade e (ii) imagens do *Google Street View* processadas usando o algoritmo de reconhecimento de imagens representam os indicadores do ambiente urbano construído. A pesquisa domiciliar foi aplicada para identificar o nível de atividade física de 1.906 indivíduos, que residem nos bairros de análise há pelo menos um ano e possuem mais de 18 anos. O questionário incluía perguntas sobre a percepção dos respondentes em relação ao uso de diferentes modos de transporte, o nível de atividade física nos deslocamentos diários ou de lazer, as características do ambiente do bairro e sobre a sua qualidade de vida. Os respondentes deviam declarar seu nível de concordância ou discordância com afirmações do tipo “É fácil atravessar as ruas do meu bairro.” As respostas utilizaram uma escala *likert* de 1 a 4, onde 1 representa a total discordância e 4 a total concordância. A pesquisa também trouxe informações sobre as características sociodemográficos dos respondentes e seu comportamento de viagem.

O *Google Street View* é a origem das imagens processadas pelos algoritmos de segmentação semântica. Elas estão disponíveis para compra utilizando *Google API* na Plataforma do *Google Cloud*. As imagens adquiridas estão alinhadas com o azimute das vias na rede viária analisada, com a altura padrão de coleta e com resolução igual a 360 x 480 pixels. A Figura 1 apresenta (a) um exemplo das imagens obtidas e a (b) a localização das imagens coletadas na rede viária (pontos roxos) e a localização da residência dos entrevistados (pontos vermelhos). Foram coletadas uma imagem a cada 50 metros da rede em uma área de estudos que incorpora o entorno caminhável de raio igual a 400m de cada residência. No total, 6.082 imagens foram obtidas e classificadas.

Os dados foram processados utilizando uma CNN (rede neural convolucional), que é comumente utilizada para lidar com imagens. A aplicação específica da CNN neste estudo é a segmentação semântica das imagens, que consiste em identificar elementos por meio da classificação de cada pixel quanto a um conjunto possível de classes a ser definido. A saída da rede neural é uma matriz $m \times n$ com a classificação de cada pixel, onde m e n representam a largura e a altura da imagem em pixels. A arquitetura de CNN escolhida foi a Deeplab (Chen

et al., 2018) por apresentar desempenho superior a arquiteturas propostas anteriormente. A versão utilizada foi treinada com uma base de imagens que contempla cenas urbanas de mais de 50 cidades chamada de *CityScape* (Cordts et al., 2016) e está disponível na biblioteca ChainerCV em linguagem de programação *Python*. Esta versão do modelo segmenta as imagens em 19 classes: *Rua*, *Construção*, *Calçada*, *Parede*, *Cerca*, *Poste*, *Semáforo*, *Sinais de trânsito*, *Vegetação*, *Terreno*, *Céu*, *Pessoa*, *Passageiro*, *Carro*, *Caminhão*, *Ônibus*, *Trem*, *Motocicleta* e *Bicicleta*., e neste estudo os valores da matriz de saída foram agrupados para construir variáveis que representam a proporção de píxeis de cada categoria identificada na imagem. Uma abordagem parecida já foi utilizada por outros autores (Rossetti et al., 2019). A escala das variáveis foi ajustada para uma forma logarítmica buscando melhorar o ajuste do modelo.

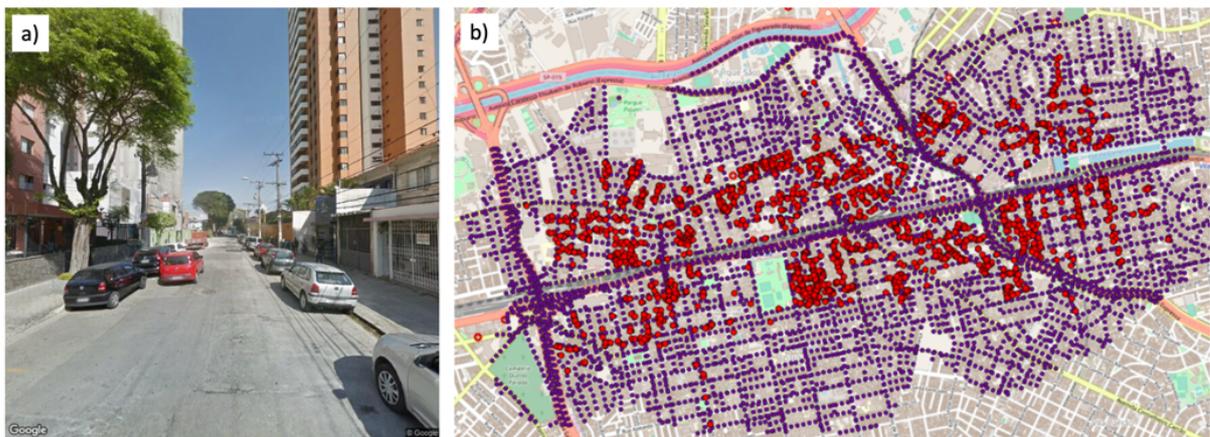


Figura 1: (a) Exemplo das imagens obtidas via *Google Street View*, (b) área de estudo e localização das imagens (pontos roxos) e residência dos entrevistados (pontos vermelhos)

3 MÉTODO E ESTRUTURA TEÓRICA

Com o objetivo de avaliar como os atributos do ambiente construído afetam a percepção da caminhabilidade e o comportamento de viagens, foi proposta a construção de quatro variáveis latentes. Três delas baseiam-se nos indicadores de percepção (*Caminhabilidade*, *Segurança Pública* e *Qualidade de Vida*). Essas três variáveis latentes e seus indicadores já foram testadas formalmente em outros estudos usando estruturas de modelos similares (Lucchesi et al., 2020; Lucchesi et al., 2020). Diferentemente dos esforços anteriores para entender o papel das percepções nos processos de decisão de viagem, agora é incorporada a variável latente *Ambiente Construído*, agregando indicadores medidos da condição do ambiente urbano. O ambiente é a primeira fonte de informação dos usuários para formar suas percepções. Baseados nas percepções da condição existente do ambiente, indivíduos decidem quando caminhar. O modelo avaliado neste estudo representa esse processo de decisão através de um diagrama de caminho apresentado na Figura 2.

Conforme apresentado na Figura 2, dividimos o indicador de ambiente construído em dois macro grupos: (i) indicadores do ambiente urbano que incentivam à caminhada, e (ii) indicadores do ambiente urbano que inibem a caminhada. No entanto, os indivíduos não percebem as características do ambiente construído de forma isolada. A combinação e interação dos atributos formarão a percepção geral da capacidade de caminhar da vizinhança. Por isso, os indicadores de barreiras e incentivos idealizados combinam as variáveis construídas a partir do processo de segmentação semântica, representando cenas urbanas típicas. Apesar da justificativa teórica, a abordagem de agregação também é consistente com a forma intrínseca

de produção de dados. Como o número de píxeis na imagem é finito, os atributos produzidos são altamente correlacionados. Portanto, a combinação dos atributos ajuda a reduzir os efeitos da correlação e podem fornecer informações adicionais sobre a contribuição (ou não) do ambiente urbano para a percepção da caminhabilidade. A Tabela 1 apresenta os indicadores propostos, sua descrição e as variáveis que foram combinadas em cada indicador. A Figura 3 apresenta as amostras de imagens dos locais que apresentam os maiores valores para cada cena urbana. Todos os indicadores foram agregados no setor censitário para representar o entorno do domicílio.



Figura 2: Estrutura teórica testada.

Tabela 1: Construção dos indicadores – Cenas urbanas avaliadas

Cenas Urbanas	Variáveis <i>Deeplab</i>	Descrição
Incentivos		
<i>Presença de não motorizados</i>	<i>Pessoas + Bicicletas</i>	Presença de pedestres e ciclistas representando áreas usadas para meios de transporte não motorizados.
<i>Áreas de alta densidade</i>	<i>Calçada + Construção + Pessoas</i>	Representação de áreas mais densas (área da imagem ocupada por edifícios) com espaço para pedestres e presença de pessoas.
<i>Áreas iluminadas</i>	<i>Calçadas + Poste</i>	Espaços para pedestres iluminados.
<i>Áreas verdes</i>	<i>Calçada + Vegetação</i>	Parques ou áreas com presença de árvores e espaços dedicados aos pedestres.
<i>Proximidade ao transporte público</i>	<i>Pessoa + Ônibus + Calçada</i>	Áreas próximas ao transporte público acessíveis para pedestres.
Barreiras		
<i>Ambientes confinados</i>	<i>Carro + Parede</i>	Túneis ou ruas com fachadas próximas que podem parecer espaços confinados para pedestres.
<i>Áreas orientadas para o carro</i>	<i>Carro + Sinais de trânsito</i>	Áreas que promovem e são usadas por modos motorizados individuais.
<i>Presença de veículos pesados</i>	<i>Caminhão + Ônibus</i>	Áreas com intensa presença de veículos pesados.
<i>Rodovias urbanas</i>	<i>Rua + Carro + Céu</i>	Estradas abertas e largas com grande presença de veículos
<i>Áreas desocupadas</i>	<i>Céu + Terreno</i>	Ruas desertas com poucas construções ou pessoas circulando



Figura 3: Cenas urbanas avaliadas

Para confirmar as teorias de agrupamentos dos atributos e a relação proposta entre o ambiente construído, as percepções e o comportamento de viagem, é necessário utilizar uma técnica confirmatória de análise. Os modelos de equações estruturais (*Structural Equation model – SEM*) são uma técnica estatística confirmatória multivariada baseada na quantificação subjacente entre variáveis latentes e variáveis observadas (Hair et al., 2017; Schreiber et al., 2006). Os modelos são uma combinação de submodelos chamados modelo estrutural e modelo de mensuração, onde o modelo de mensuração reflete a validade das relações propostas entre as variáveis latentes e seus indicadores, e o modelo estrutural reflete as inter-relações entre os construtos latentes e entre variáveis latentes e variáveis respostas (Hair et al., 2017; Schreiber et al., 2006). O quão bem o modelo representa a teoria proposta é avaliado através dos sinais e significados dos coeficientes e pelos índices de qualidade de ajuste. Os índices de qualidade de ajuste utilizados são recomendados por Schumacker e Lomax (2010) e Hair *et al.* (2017), incluindo *Root-Mean-Square Error of Approximation* ($RMSEA < 0,08$) (Steiger, 2016) e o *Comparative Fit Index* ($CFI \geq 0,90$) (Bentler e Bonett, 1980).

4 RESULTADOS

4.1 Construção dos indicadores

O primeiro resultado do estudo está relacionado à construção dos indicadores do ambiente construído. A Figura 4 apresenta a distribuição das barreiras e incentivos na área de estudo. Vermelho representa, em ambos os casos, as piores condições para os pedestres, e as faixas de cor foram divididas com base nos quartis de cada cena urbana. Os números no rótulo apresentam a variância de cada indicador.

Conforme apresentado na Figura 4, existem algumas semelhanças entre os padrões de cores dos mapas das cenas urbanas que representam as barreiras e os incentivos. Porém, olhando as cenas urbanas consideradas incentivadoras que combinam atributos semelhantes (ex.: todos incluem a variável *Calçadas*), é possível notar diferenças essenciais, principalmente no lado esquerdo das áreas de estudo. Uma conclusão semelhante pode ser tirada olhando para as cenas que representam barreiras. Sendo assim, os atributos isolados representam apenas a presença, ou não, dos elementos como calçadas, luzes, árvores, carros etc. No entanto, os atributos combinados adicionam um nível extra de complexidade aos dados representado por essas diferenças de padrão nas manchas de cor do mapa.

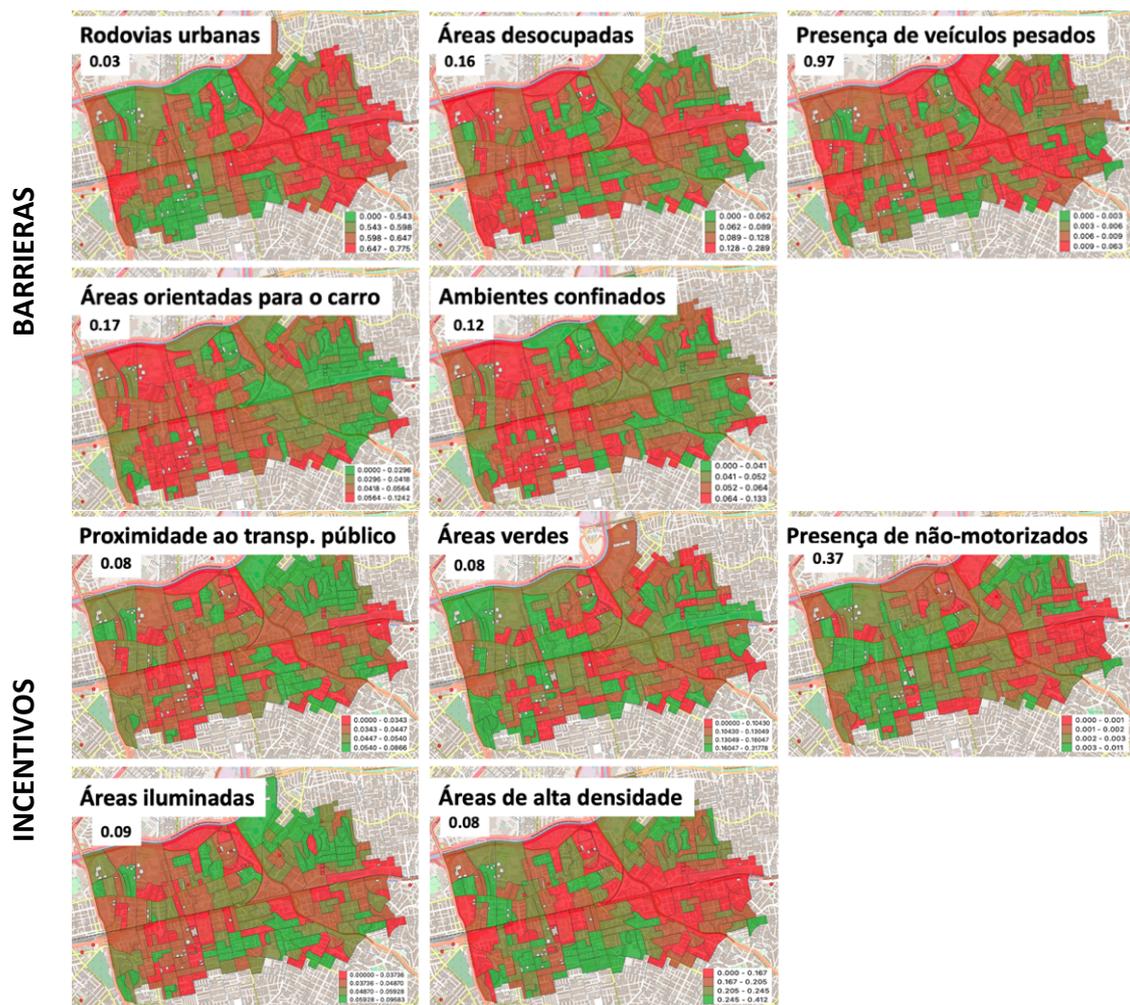


Figura 4: Avaliação dos agrupamentos dos indicadores na área de estudo

4.2 Resultados do modelo de equações estruturais

Usamos um modelo SEM para testar se os algoritmos de aprendizado de máquina podem produzir dados de ambiente construído confiáveis e estatisticamente significativos. A Tabela 2 apresenta os resultados do modelo de medição e a Tabela 3 do modelo estrutural.

Tabela 2: Resultados do modelo de mensuração

Indicadores	Coefficientes	Coefficientes normalizados	Valor-p
Indicadores da variável latente <i>Ambiente Construído</i>			
<i>Áreas iluminadas</i>	0.169	0.730	0.000
<i>Proximidade ao transporte público</i>	0.147	0.699	0.000
<i>Áreas de alta densidade</i>	0.146	0.526	0.000
<i>Presença de não motorizados</i>	0.185	0.339	0.000
<i>Presença de veículos pesados</i>	-0.057	-0.087	0.000
<i>Ambientes confinados</i>	-0.034	-0.119	0.000
<i>Áreas desocupadas</i>	-0.055	-0.134	0.000
<i>Áreas verdes</i>	-0.041	-0.139	0.000
<i>Áreas orientadas para o carro</i>	-0.120	-0.321	0.000
<i>Rodovias urbanas</i>	-0.068	-0.533	0.000

Os resultados obtidos para as variáveis latentes relativas a percepções são semelhantes aos obtidos em outros estudos, nos quais foi testado um modelo semelhante (Lucchesi et al., 2020; Lucchesi et al., 2020). Portanto, focaremos a discussão dos resultados nas contribuições dos algoritmos de reconhecimento de imagens na construção dos indicadores de incentivos e barreiras, e seus impactos na percepção da caminhabilidade e no comportamento de viagem. O ajuste do modelo foi satisfatório, com índice CFI igual a 0,906 e RMSEA igual a 0,051. Todas as variáveis são significativas, considerando um nível de confiança de 95%. Esses resultados confirmam a primeira hipótese do estudo. Variáveis processadas usando imagens do *Google Street View* e algoritmos de aprendizado de máquina para capturar dados usando reconhecimento de imagem podem representar padrões de ambiente integrados em modelos de pedestres.

Os sinais dos indicadores de percepção estão todos conforme o esperado, com todas as variáveis contribuindo positivamente para a variável latente, exceto a variável Crimes (contribuição negativa para a percepção de segurança pública). Observando os indicadores da variável latente *Ambiente Construído*, todas as variáveis que representam barreiras à caminhada apresentaram sinais negativos. Nos incentivos, as variáveis *Áreas iluminadas*, *Proximidade ao transporte público*, *Área de alta densidade* e *Presença de não motorizados* contribuem positivamente para a variável latente. Por outro lado, o indicador *Áreas verdes* afeta negativamente a variável latente, demonstrando que as áreas onde há calçadas e presença intensa de árvores pode representar não incentivos, mas barreiras para pedestres.

O sinal e significância dos parâmetros estimados apresentados na tabela 3 evidenciam que a variável latente do *Ambiente Construído* afeta positivamente a *Caminhabilidade*. Consequentemente é possível afirmar que os indicadores da variável latente *Ambiente Construído* mantêm seus sinais quanto ao impacto na latente *Caminhabilidade*. Isto é, as barreiras impactam negativamente à percepção de caminhabilidade e os incentivos estimulam a percepção favorável do ambiente para caminhar. A partir desse resultado, confirmamos que a combinação dos atributos propostos afeta a percepção da capacidade de locomoção e representam as cenas urbanas amigáveis ou hostis aos pedestres.

Tabela 3: Resultados do modelo de estrutural

Relações estruturais		Coefficientes	Coefficientes normalizados	Valor-p	
Variáveis endógenas					
<i>Segurança Pública</i>	→	<i>Caminhabilidade</i>	0.514	0.392	0.000
<i>Qualidade de Vida</i>	→	<i>Caminhabilidade</i>	0.518	0.404	0.000
<i>Ambiente Construído</i>	→	<i>Caminhabilidade</i>	0.098	0.075	0.015
<i>Caminhabilidade</i>	→	<i>Frequência de caminhada</i>	0.137	0.079	0.006
Variáveis exógenas					
<i>Idade</i>	→	<i>Caminhabilidade</i>	0.006	0.070	0.011
<i>Escolaridade</i>	→	<i>Caminhabilidade</i>	0.054	0.064	0.035
<i>Carro disponível</i>	→	<i>Caminhabilidade</i>	-0.442	-0.167	0.000
<i>Idade</i>	→	<i>Qualidade de Vida</i>	-0.008	-0.128	0.000
<i>Escolaridade</i>	→	<i>Qualidade de Vida</i>	0.069	0.104	0.000
<i>Carro disponível</i>	→	<i>Qualidade de Vida</i>	0.200	0.097	0.001
Efeitos indiretos					
<i>Ambiente construído</i>	→	<i>Frequência de caminhada</i>	0.013	0.006	0.057
<i>Segurança Pública</i>	→	<i>Frequência de caminhada</i>	0.070	0.031	0.006
<i>Qualidade de Vida</i>	→	<i>Frequência de caminhada</i>	0.071	0.021	0.006

O efeito das variáveis socioeconômicas sobre as variáveis latentes é significativo e apresentou os sinais esperados. A idade (0,07) e o nível de escolaridade (0,064) impactam positivamente a

percepção da caminhabilidade, enquanto o acesso ao carro faz os indivíduos perceberem o ambiente como menos caminhável (-0,167). Por outro lado, a disponibilidade de carro afeta positivamente a percepção da qualidade de vida (0,097), com o nível de escolaridade (0,104) e a idade negativamente (-0,128). As variáveis exógenas não influenciam a segurança da vizinhança nos modelos, dado que os efeitos não são estatisticamente significativos. Outras variáveis exógenas testadas que representavam gênero e tempo de residência no bairro também não produziram resultados significativos.

Finalmente, a Tabela 3 também apresenta como as percepções e o ambiente construído afetam o comportamento de viagem. Pode-se dizer que os indicadores de barreiras e incentivos que caracterizam a variável latentes do *Ambiente Construído* afetam a frequência de caminhada de maneira indireta. A magnitude reduzida dos efeitos indiretos desta latente na frequência de caminhada em comparação com o efeito da latente *Caminhabilidade* na variável exógena atesta que a percepção medeia fortemente o efeito. A significância a 90% de confiança (valor-p) pode estar relacionada ao teste que o *MPlus* realiza para significância que pressupõe normalidade, o que não é necessariamente verdadeiro para as multiplicações avaliadas nos efeitos indiretos (MacKinnon, 2012). Os constructos *Segurança Pública* e a *Qualidade de Vida* também contribuem indiretamente para a frequência de caminhada.

5 IMPLICAÇÕES DOS RESULTADOS PARA PROMOÇÃO DOS DESLOCAMENTOS A PÉ

Os resultados evidenciam o impacto que ambientes desfavoráveis, hostis, aos pedestres produzem na promoção de modos de transporte sustentáveis em áreas altamente urbanizadas. A barreira que mostrou ter maior impacto está relacionada à presença de rodovias urbanas. A presença desses ambientes próximos à residência desestimula a caminhada. Analisando os dados, observa-se que a área de estudo conta com três rodovias urbanas que promovem menores oportunidades de travessia (3 travessias em 4 km). Aumentar as oportunidades de travessia pode ser uma solução para criar um ambiente mais amigável para os pedestres. Os dados mostraram que os residentes que concordaram com a facilidade de atravessar as ruas em seus bairros também perceberam a área como mais caminhável (ver resultados do modelo de mensuração na Tabela 2). Da mesma forma, as áreas orientadas para o carro mostraram ser a segunda barreira que mais impacta negativamente o pedestre, na área estudada.

Um interessante resultado do estudo é que as áreas com grande presença de vegetação são percebidas como menos caminháveis (sinal negativo para a variável do ambiente construído). Este resultado contradiz a estrutura do modelo, onde foi assumido que a vegetação colaboraria para incentivar a caminhada. No entanto, há evidências na literatura de que as áreas verdes podem afetar a caminhabilidade de forma positiva e negativa. Enquanto alguns autores identificam a contribuição dos espaços verdes para o bem-estar e atividade física (Carrus et al., 2015; Kim et al., 2014; Lu, 2018), outros destacam que a presença de parques e árvores pode ser prejudicial, principalmente devido a percepções de segurança (Groff e McCord, 2012; Nagata *et al.*, 2020). No caso de cidades latino-americanas como São Paulo, a segurança pública é uma preocupação de quem caminha o que também foi verificado pela relação das variáveis latentes nesse estudo. Outros trabalhos realizados no Brasil e em outros países da América Latina (Cantillo et al., 2015; Larranaga et al., 2018; Lucchesi et al., 2020) demonstraram que a percepção de segurança é uma consideração importante na escolha de rota e escolha de modo. Assim, ruas com grande presença de árvores também podem ser percebidas como locais inseguros. Além disso, o indicador de incentivo à caminhabilidade é construído de forma que

quanto maior o número de píxeis categorizados como vegetação, maior a pontuação do indicador.

Quanto aos incentivos, a combinação de calçadas e postes apresentou os maiores coeficientes para as variáveis latentes do ambiente construído e, conseqüentemente, para a percepção da caminhabilidade e da frequência de caminhada. Neste estudo, foi considerado que a presença de postes é uma boa proxy para representar iluminação urbana. Embora a iluminação noturna seja um dos indicadores de menor impacto para a percepção da caminhabilidade no modelo de mensuração, locais onde as calçadas possuem iluminação podem representar uma infraestrutura mais completa e de boa qualidade para os pedestres. A área de estudo é considerada de baixa a média renda, locais onde pedestres comumente enfrentam desafios para encontrar infraestrutura adequada.

A segunda cena urbana que mais incentiva a caminhar é aquela em que há presença a proximidade ao transporte público. Estas cenas urbanas combinam píxeis categorizados como calçadas, ônibus e pessoas. A presença de ônibus na imagem significa que a área é servida por linhas de ônibus. Embora o algoritmo não consiga capturar se o veículo faz parte da frota de transporte público, é um ônibus escolar ou fretado. Mesmo assim, a influência do transporte público também é vista nos construtos *Caminhabilidade e Segurança Pública*, reforçando a validade dos resultados. Ressalta-se que os entrevistados são usuários frequentes de transporte público (45% usam transporte público pelo menos uma vez por semana), e a área é bem servida por linhas de ônibus e estações de trem metropolitanas. O alto uso do transporte público não é incomum em megacidades latino-americanas como São Paulo, onde os indivíduos precisam fazer viagens mais longas para ter acesso a oportunidades de emprego e não podem pagar por opções de motorização privada (Boisjoly et al., 2017; Slovic et al., 2019). Portanto, as estratégias de promoção da caminhabilidade não podem ser isoladas. As políticas de transporte sustentável devem considerar uma perspectiva multimodal e integrada para promover possíveis substitutos para o carro (Bozovic et al., 2021).

Vale ressaltar também que a densidade é um indicador tradicional da caminhabilidade. Geralmente é tratada como densidade populacional ou densidade de emprego nos modelos econométricos de pedestres (Cervero e Kockelman, 1997). Portanto, além de testar o efeito da densidade para promover deslocamentos a pé – algo já bastante documentado na literatura – o modelo testa se a presença de edifícios em si representará o conceito. A combinação de edifícios, calçadas e pessoas representa a terceira cena urbana mais importante para o construto *Ambiente Construído* e, conseqüentemente, para a caminhabilidade e a frequência de caminhada.

Finalmente, os resultados mostram que o ambiente construído pode afetar o comportamento de viagem. No entanto, as percepções dos indivíduos sobre o bairro mediarão esses efeitos. Isso significa que os indivíduos interpretam as variáveis medidas do ambiente construído de forma subjetiva, considerando suas experiências e conhecimentos prévios, como as representadas no construto *Qualidade de Vida*. No entanto, a forma urbana e os elementos do ambiente construído podem ser influenciados por planejadores urbanos e de transporte. Portanto, compreender como cada combinação de atributos do ambiente construído no nível da rua pode afetar positiva e negativamente a vontade de caminhar ajudará a promover cenas urbanas voltadas para pedestres e mais atraentes para deslocamentos a pé.

6 CONSIDERAÇÕES FINAIS

Caminhar é uma experiência ao nível dos olhos e os elementos que os pedestres observam afetam sua disposição ao caminhar. Embora muitos estudos adotem dados de mesoescala para avaliar caminhabilidade e frequência de caminhada, novas tecnologias promovem uma solução mais fácil e acessível para coletar dados em microescala que representam o que os pedestres veem e sentem nas ruas. Assim, este estudo processou imagens disponíveis no *Google Street View* usando algoritmos de aprendizado de máquina desenvolvidos para produzir dados de segmentação de classe para caracterizar o ambiente urbano. Os atributos processados usando os algoritmos foram combinados buscando identificar cenas urbanas que representam barreiras ou incentivos para andar a pé.

Apesar de as áreas verdes apresentarem efeitos negativos na percepção da caminhabilidade, o modelo SEM confirma o impacto dos demais atributos no caráter geral do ambiente construído. O modelo também verifica os impactos do ambiente construído na frequência de caminhada, mediados pela percepção da caminhabilidade geral do bairro. Portanto, os dados produzidos usando algoritmos de aprendizado de máquina podem ajudar a identificar barreiras e incentivos para caminhar representando cenas do ambiente urbano e os resultados atestam a aplicação de reconhecimento de imagem para produzir dados secundários em modelos econométricos de percepção de caminhabilidade.

Os resultados deste estudo são relevantes para a comunidade acadêmica e planejadores de transporte, dado que um modelo de reconhecimento de imagem que identifica elementos da infraestrutura urbana e produz resultados confiáveis pode trazer diversos avanços na pesquisa em transporte, especialmente para estudos com pedestres. A determinação de forma automática de locais já sabidamente atuantes como barreiras a caminhada pode auxiliar a direcionar políticas públicas e ações de redesenho do ambiente para eliminação destas barreiras e promoção da mobilidade a pé. A automatização destes processos de coleta e interpretação dos dados apoiam no aumento da escala de análise. Migrando de escalas locais ou ao nível do bairro para análises ao nível de cidade e/ou região metropolitana.

No entanto, ainda existem oportunidades de melhoria dos modelos. O banco de imagens CityScapes, utilizado para o treinamento da CNN escolhida, contempla uma gama limitada de elementos urbanos escolhidos por seus idealizadores. Portanto, treinar os algoritmos para incorporar mais elementos do ambiente construído relevantes para os estudos dos pedestres pode aumentar sua efetividade neste tipo de aplicação. Alguns exemplos são a presença de lojas, mobiliário urbano (por exemplo, bancos), fachadas ativas e outros elementos no nível da rua que podem afetar a percepção da caminhabilidade na microescala. Além disso, apesar de o *Google Street View* ser uma fonte rica de imagens urbanas as imagens ainda são coletadas do ponto de visão do motorista e não dos pedestres. Coletar as imagens do ponto de vista da calçada pode criar atributos mais fiéis à experiência dos pedestres.

REFERÊNCIAS BIBLIOGRÁFICAS

- Anapakula, K. B., e Eranki, G. A. (2021) Developing an index to evaluate the quality of pedestrian environment: Case study application in an Indian metro. *Transportation Research Interdisciplinary Perspectives*, 11(May), 100406. doi:10.1016/j.trip.2021.100406
- Anderson, S. F. (2017) *The War Between Data and Images*. MIT Press.
- Arellana, J., Saltarin, M., Larranaga, A. M., Alvarez, V., e Henao, C. A. (2019) Urban walkability considering pedestrians' perceptions of the built environment: A 10-year review and a case study in a medium-sized city in Latin America. *Transport Reviews*, 40(2), 183–203. doi:https://doi.org/10.1080/01441647.2019.1703842
- Badrinarayanan, V., Handa, A., e Cipolla, R. (2014) SegNet: A Deep Convolutional Encoder-Decoder Architecture for Robust Semantic Pixel-Wise Labelling. *CVPR*. Ohio. Obtido de <http://arxiv.org/abs/1505.07293>

- Bentler, P. M., e Bonett, D. G. (1980) Significance tests and goodness of fit in the analysis of covariance structures. *Psychological Bulletin*, 88(3), 588–606. doi:10.1037/0033-2909.88.3.588
- Bivina, G. R., Gupta, A., e Parida, M. (2020) Walk Accessibility to Metro Stations: An analysis based on Meso- or Micro-scale Built Environment Factors. *Sustainable Cities and Society*, 55(January), 102047. doi:10.1016/j.scs.2020.102047
- Boisjoly, G., Moreno-Monroy, A. I., e El-Geneidy, A. (2017) Informality and accessibility to jobs by public transit: Evidence from the São Paulo Metropolitan Region. *Journal of Transport Geography*, 64(May 2016), 89–96. doi:10.1016/j.jtrangeo.2017.08.005
- Bozovic, T., Stewart, T., Hinckson, E., e Smith, M. (2021) Clearing the path to transcend barriers to walking: Analysis of associations between perceptions and walking behaviour. *Transportation Research Part F: Traffic Psychology and Behaviour*, 77, 197–208. doi:10.1016/j.trf.2021.01.003
- Brown, B. B., Yamada, I., Smith, K. R., Zick, C. D., Kowaleski-Jones, L., e Fan, J. X. (2009) Mixed land use and walkability: Variations in land use measures and relationships with BMI, overweight, and obesity. *Health and Place*, 15(4), 1130–1141. doi:10.1016/j.healthplace.2009.06.008
- Cantillo, V., Arellana, J., e Rolong, M. (2015) Modelling pedestrian crossing behaviour in urban roads: A latent variable approach. *Transportation Research Part F: Traffic Psychology and Behaviour*, 32, 56–67. doi:10.1016/j.trf.2015.04.008
- Carrus, G., Scopelliti, M., Laforteza, R., Colangelo, G., Ferrini, F., Salbitano, F., Agrimi, M., Portoghesi, L., Semenzato, P., e Sanesi, G. (2015) Go greener, feel better? The positive effects of biodiversity on the well-being of individuals visiting urban and peri-urban green areas. *Landscape and Urban Planning*, 134, 221–228. doi:10.1016/j.landurbplan.2014.10.022
- Cervero, R., e Kockelman, K. (1997) Travel demand and the 3Ds: Density, diversity, and design. *Transportation Research Part D: Transport and Environment*, 2(3), 199–219. doi:10.1016/S1361-9209(97)00009-6
- Chen, L. C., Papandreou, G., Kokkinos, I., Murphy, K., e Yuille, A. L. (2018) DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 40(4), 834–848. doi:10.1109/TPAMI.2017.2699184
- Cisneros, C. (2015) *Value of Walkable Communities*.
- Clark, A. F., e Scott, D. M. (2016) Barriers to walking: An investigation of adults in Hamilton (Ontario, Canada). *International Journal of Environmental Research and Public Health*, 13(2). doi:10.3390/ijerph13020179
- Cordts, M., Omran, M., Ramos, S., Rehfeld, T., Enzweiler, M., Benenson, R., Franke, U., Roth, S., e Schiele, B. (2016) The Cityscapes Dataset for Semantic Urban Scene Understanding. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-Decem*, 3213–3223. doi:10.1109/CVPR.2016.350
- Ewing, R., e Cervero, R. (2010) Travel and the built environment: a synthesis. *Transportation Research Record*, 1780(Paper No. 01-3515), 87–114. doi:10.3141/1780-10
- Ewing, Reid, Clemente, O., Neckerman, K. M., Purciel-Hill, M., Quinn, J. W., e Rundle, A. (2013) *Measuring Urban Design. Measuring Urban Design - Metrics for livable places*. Island Press, Washington | Covelo | London. doi:10.5822/978-1-61091-209-9
- Ferrer, S., Ruiz, T., e Mars, L. (2015) A qualitative study on the role of the built environment for short walking trips. *Transportation Research Part F: Traffic Psychology and Behaviour*, 33, 141–160. doi:10.1016/j.trf.2015.07.014
- Forsyth, A. (2015) What is a walkable place? The walkability debate in urban design. *Urban Design International*, 20(4), 274–292. doi:10.1057/udi.2015.22
- Groff, E., e McCord, E. S. (2012) The role of neighborhood parks as crime generators. *Security Journal*, 25(1), 1–24. doi:10.1057/sj.2011.1
- Hair, J. F., Black, W. C., Babin, B. J., Anderson, R. E., e Tatham, R. L. (2017) *Multivariate Data Analysis*. (PEL, Ed) (7th ed.). Bookman, Essex.
- Handy, S. (2018) Enough with the “D’s” Already — Let’s Get Back to “A.” *Transfers Magazine, Spring 201*, 1–3.
- Ilarri, S., Stojanovic, D., e Ray, C. (2015) Semantic management of moving objects: A vision towards smart mobility. *Expert Systems with Applications*, 42(3), 1418–1435. doi:https://doi.org/10.1016/j.eswa.2014.08.057
- Jun, H. J., e Hur, M. (2015) The relationship between walkability and neighborhood social environment: The importance of physical and perceived walkability. *Applied Geography*, 62, 115–124. doi:10.1016/j.apgeog.2015.04.014
- Kang, C. D. (2018) The S + 5Ds: Spatial access to pedestrian environments and walking in Seoul, Korea. *Cities*, 77(February), 130–141. doi:10.1016/j.cities.2018.01.019
- Kim, S., Park, S., e Lee, J. S. (2014) Meso-or micro-scale? Environmental factors influencing pedestrian satisfaction. *Transportation Research Part D: Transport and Environment*, 30, 10–20.
- Larranaga, A. M., Arellana, J., Rizzi, L. I., Strambi, O., e Cybis, H. B. B. (2018) *Using best–worst scaling to identify barriers to walkability: a study of Porto Alegre, Brazil*. *Transportation*. Springer US. doi:10.1007/s11116-018-9944-x
- Li, M., Liu, J., Lin, Y., Xiao, L., e Zhou, J. (2021) Revitalizing historic districts: Identifying built environment predictors for street vibrancy based on urban sensor data. *Cities*, 117(May), 103305. doi:10.1016/j.cities.2021.103305
- Lu, Y. (2018) Using Google Street View to investigate the association between street greenery and physical activity. *Landscape and Urban Planning*, (July). doi:10.1016/j.landurbplan.2018.08.029
- Lucchesi, S. T., Larranaga, A. M., Bettella Cybis, H. B., de Abreu e Silva, J. A., e Arellana, J. A. (2020) Are people willing to pay more to live in a walking environment? A multigroup analysis of the impact of walkability on real estate values and their moderation effects in two Global South cities. *Research in Transportation Economics*, (October). doi:10.1016/j.retrec.2020.100976
- Lucchesi, S. T., Larranaga, A. M., Ochoa, J. A. A., Samios, A. A. B., e Cybis, H. B. B. (2020) The role of security and walkability in subjective wellbeing: A multigroup analysis among different age cohorts. *Research in Transportation*

- Business and Management*, (September), 100559. doi:10.1016/j.rtbm.2020.100559
- Ma, L., e Cao, J. (2019) How perceptions mediate the effects of the built environment on travel behavior? *Transportation*, 46(1), 175–197. doi:10.1007/s11116-017-9800-4
- Ma, L., e Dill, J. (2017) Do people’s perceptions of neighborhood bikeability match “reality”? *Journal of Transport and Land Use*, 10(1), 291–308. doi:10.5198/jtlu.2016.796
- Ma, X., Ma, C., Wu, C., Xi, Y., Yang, R., Peng, N., Zhang, C., e Ren, F. (2021) Measuring human perceptions of streetscapes to better inform urban renewal: A perspective of scene semantic parsing. *Cities*, 110(October 2020), 103086. doi:10.1016/j.cities.2020.103086
- MacKinnon, D. P. (2012) Introduction to Statistical Mediation Analysis. *Introduction to Statistical Mediation Analysis*. doi:10.4324/9780203809556
- Marshall, J. D., Brauer, M., e Frank, L. D. (2009) Healthy neighborhoods: Walkability and air pollution. *Environmental Health Perspectives*, 117(11), 1752–1759. doi:10.1289/ehp.0900595
- Moura, F., Cambra, P., e Gonçalves, A. B. (2017) Measuring walkability for distinct pedestrian groups with a participatory assessment method: A case study in Lisbon. *Landscape and Urban Planning*, 157, 282–296. doi:10.1016/j.landurbplan.2016.07.002
- Nagata, S., Nakaya, T., Hanibuchi, T., Amagasa, S., Kikuchi, H., e Inoue, S. (2020) Objective scoring of streetscape walkability related to leisure walking: Statistical modeling approach with semantic segmentation of Google Street View images. *Health and Place*, 66, 102428. doi:10.1016/j.healthplace.2020.102428
- Rossetti, T., Lobel, H., Rocco, V., e Hurtubia, R. (2019) Explaining subjective perceptions of public spaces as a function of the built environment: A massive data approach. *Landscape and Urban Planning*, 181(September 2018), 169–178. doi:10.1016/j.landurbplan.2018.09.020
- Schreiber, J. B., Nora, A., Stage, F. K., Balow, E. A., e King, J. (2006) Reporting Structural Equation Modeling and Confirmatory Factor Analysis Results: A Review. *The Journal of Educational Research*, 99(6), 323–338. doi:https://doi.org/10.3200/JOER.99.6.323-338
- Singleton, P. A., e Wang, L. (2014) Safety and Security in Discretionary Travel Decision Making. *Transportation Research Record: Journal of the Transportation Research Board*, 2430(1), 47–58. doi:10.3141/2430-06
- Slovic, A. D., Tomasiello, D. B., Giannotti, M., Andrade, M. de F., e Nardocci, A. C. (2019) The long road to achieving equity: Job accessibility restrictions and overlapping inequalities in the city of São Paulo. *Journal of Transport Geography*, 78(March), 181–193. doi:10.1016/j.jtrangeo.2019.06.003
- Steiger, J. H. (2016) Notes on the Steiger–Lind (1980) Handout. *Structural Equation Modeling*, 23(6), 777–781. doi:10.1080/10705511.2016.1217487
- van den Berg, P., Sharmeen, F., e Weijs-Perrée, M. (2017) On the subjective quality of social Interactions: Influence of neighborhood walkability, social cohesion and mobility choices. *Transportation Research Part A: Policy and Practice*, 106(October), 309–319. doi:10.1016/j.tra.2017.09.021
- Wang, Y., Chau, C. K., Ng, W. Y., e Leung, T. M. (2016) A review on the effects of physical built environment attributes on enhancing walking and cycling activity levels within residential neighborhoods. *Cities*, 50, 1–15. doi:10.1016/j.cities.2015.08.004
- Yin, L., Cheng, Q., Wang, Z., e Shao, Z. (2015) “Big data” for pedestrian volume: Exploring the use of Google Street View images for pedestrian counts. *Applied Geography*, 63, 337–345. doi:10.1016/j.apgeog.2015.07.010