



Explicando las percepciones subjetivas de los espacios públicos en función del entorno construido: un enfoque de datos masivos

# Explaining subjective perceptions of public spaces as a function of the built environment: **A massive data approach**

Rossetti, T., Lobel, H., Rocco, V., & 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, 169-178.

Javiera Celedón  
Macarena Jiménez  
Ximena Rifo  
Yerko Sanhueza  
Tamara San Martín

# PREGUNTA DE INVESTIGACIÓN



¿CÓMO?

ESPACIO  
CONSTRUIDO /  
ENTORNO

AFECTA

PERCEPCIÓN DE LOS  
ESPACIOS PÚBLICOS



Los paisajes urbanos son experimentados por sus usuarios en gran parte a través de percepciones visuales. Esto ha sido explorado en la literatura, mostrando que las percepciones pueden influir en la intensidad de uso de los espacios públicos o fomentar el uso de determinados modos de transporte.

## Keywords

Perceptions / Percepciones  
Discrete choice models / Modelos de elección discreta  
Machine learning / Aprendizaje automático  
Public spaces/ Espacios públicos

# CONTEXTO



**Keywords**  
Perceptions / Percepciones  
Discrete choice models / Modelos de elección discreta  
Machine learning / Aprendizaje automático  
Public spaces/ Espacios públicos

¿Qué dice la literatura al respecto?

Puede Influenciar la intensidad del uso del espacio público

(Khisty, 1994; Shriver, 1997)


Incluso puede animar a las personas a utilizar cierto tipo, y no otro, de transporte

(Antonakos, 1995; Hunt & Abraham, 2007; Hyodo, Suzuki, & Takahashi, 2000; Jiang, Christopher Zegras, & Mehndiratta, 2012; Tilahun and Li, 2015; Zacharias, 2001)




a la toma de decisiones en Políticas Públicas?

Permite identificar posibles intervenciones que pueden empujar el comportamiento de los usuarios hacia prácticas más sostenibles, como preferir **barrios más densos** o transporte activo.



# OBJETIVO DEL PAPER

**Cuantificar** la relación entre indicadores perceptivos con indicadores observables de paisajes.



Para ello además se debe lograr identificar cuantitativamente **qué elementos físicos de los espacios públicos** inciden en las percepciones cualitativas.



# BRECHAS DE CONOCIMIENTO

## ANTES


La literatura reporta múltiples esfuerzos por cuantificar estas percepciones, teniendo que lidiar con **costosos procesos de colección de datos.**

## RECIENTEMENTE

Sin embargo, literatura más reciente ha usado **técnicas de recolección de datos masivas** para cuantificar estas percepciones.

## ...PERO

A pesar de las ventajas de estos modelos respecto al procesamiento de datos y habilidades predictivas, **no proveen una información que explique directamente el móvil detrás de las decisiones de los encuestados.**



Propone una metodología novedosa para cuantificar las percepciones de imágenes de espacios públicos utilizando un conjunto de datos masivo: **Place Pulse**

Utiliza **Google Street View** que hacen pública de manera gratuita una cobertura virtualmente global de imágenes bidimensionales de espacios públicos en varias ciudades.

Usa las **imágenes** de Google Street View para **mostrar dos de ellas frente a frente**, preguntando al lector, entre otras cosas, cuál de las dos nos parece una región más segura.



# METODOLOGÍA: RECOPIACIÓN DE DATOS

## Place Pulse

Este proyecto del MIT recopiló una **base de datos mediante una encuesta** en la que se presentaron al azar dos **imágenes** al encuestado/a, obtenidas de **Google Street View**.



A continuación, se les solicitó indicar **cuál de las dos imágenes se ajustaba mejor a un adjetivo específico**. Los adjetivos utilizados fueron: **hermoso, aburrido, deprimente y animado**.

Which place looks safer ?



**Fig. 1.** Example of choice experiment presented in Place Pulse.



# METODOLOGÍA: MODELO NO LINEAL DE ELECCIÓN DISCRETA COMPLEMENTADO CON MACHINE LEARNING (Part.1)

Selección minuciosa de imágenes previamente asociadas a adjetivos.

## Principal Propósito

Identificar qué características específicas están vinculadas a estos adjetivos. Para lograrlo, se implementó un proceso de parametrización de las imágenes.

# METODOLOGÍA: MODELO NO LINEAL DE ELECCIÓN DISCRETA COMPLEMENTADO CON MACHINE LEARNING (Part.2)

La parametrización se llevó a cabo en dos niveles:






Fig. 2. Example of images presented in the Place Pulse dataset (left) and edges detected in it (right).

**Características de bajo nivel:**  
Se incluyeron aspectos como los bordes presentes en la imagen o el número de objetos grandes.




Bajo costo operacional




Píxeles  
Colores  
Texturas  
Canales, entre otros.

**Características de alto nivel:**  
Inicialmente tiene problemas de segmentación semántica (reconocimiento de elementos en las imágenes)



Resuelto por una herramienta de aprendizaje automático



Se utilizó **SegNet** entrenado con muestra de datos de CamVid (videos grabados cerca de cambridge)



Edificio,  
Auto  
Ciclista, entre otros.





# METODOLOGÍA: MODELO NO LINEAL DE ELECCIÓN DISCRETA COMPLEMENTADO CON MACHINE LEARNING



Después de la parametrización de las imágenes y la extracción de las características del entorno



se emplea un **modelo no lineal** para determinar los pesos, o importancia, que las **características de los espacios** puedan ejercer en la **formación de las percepciones** de las personas sobre dichos espacios.



Este enfoque permite comprender **cómo estas características influyen** en la configuración de las percepciones individuales.



# METODOLOGÍA: SUPUESTOS

## Supuesto 1:

Atributos cualitativos como las percepciones pueden explicarse a través de variables observables (características de las imágenes y características de los(as) observadores)

## Supuesto 2:

Las percepciones se manifiestan a través de variables observables. Las percepciones se relacionan con un indicador de percepción.

# METODOLOGÍA: ESTRUCTURA

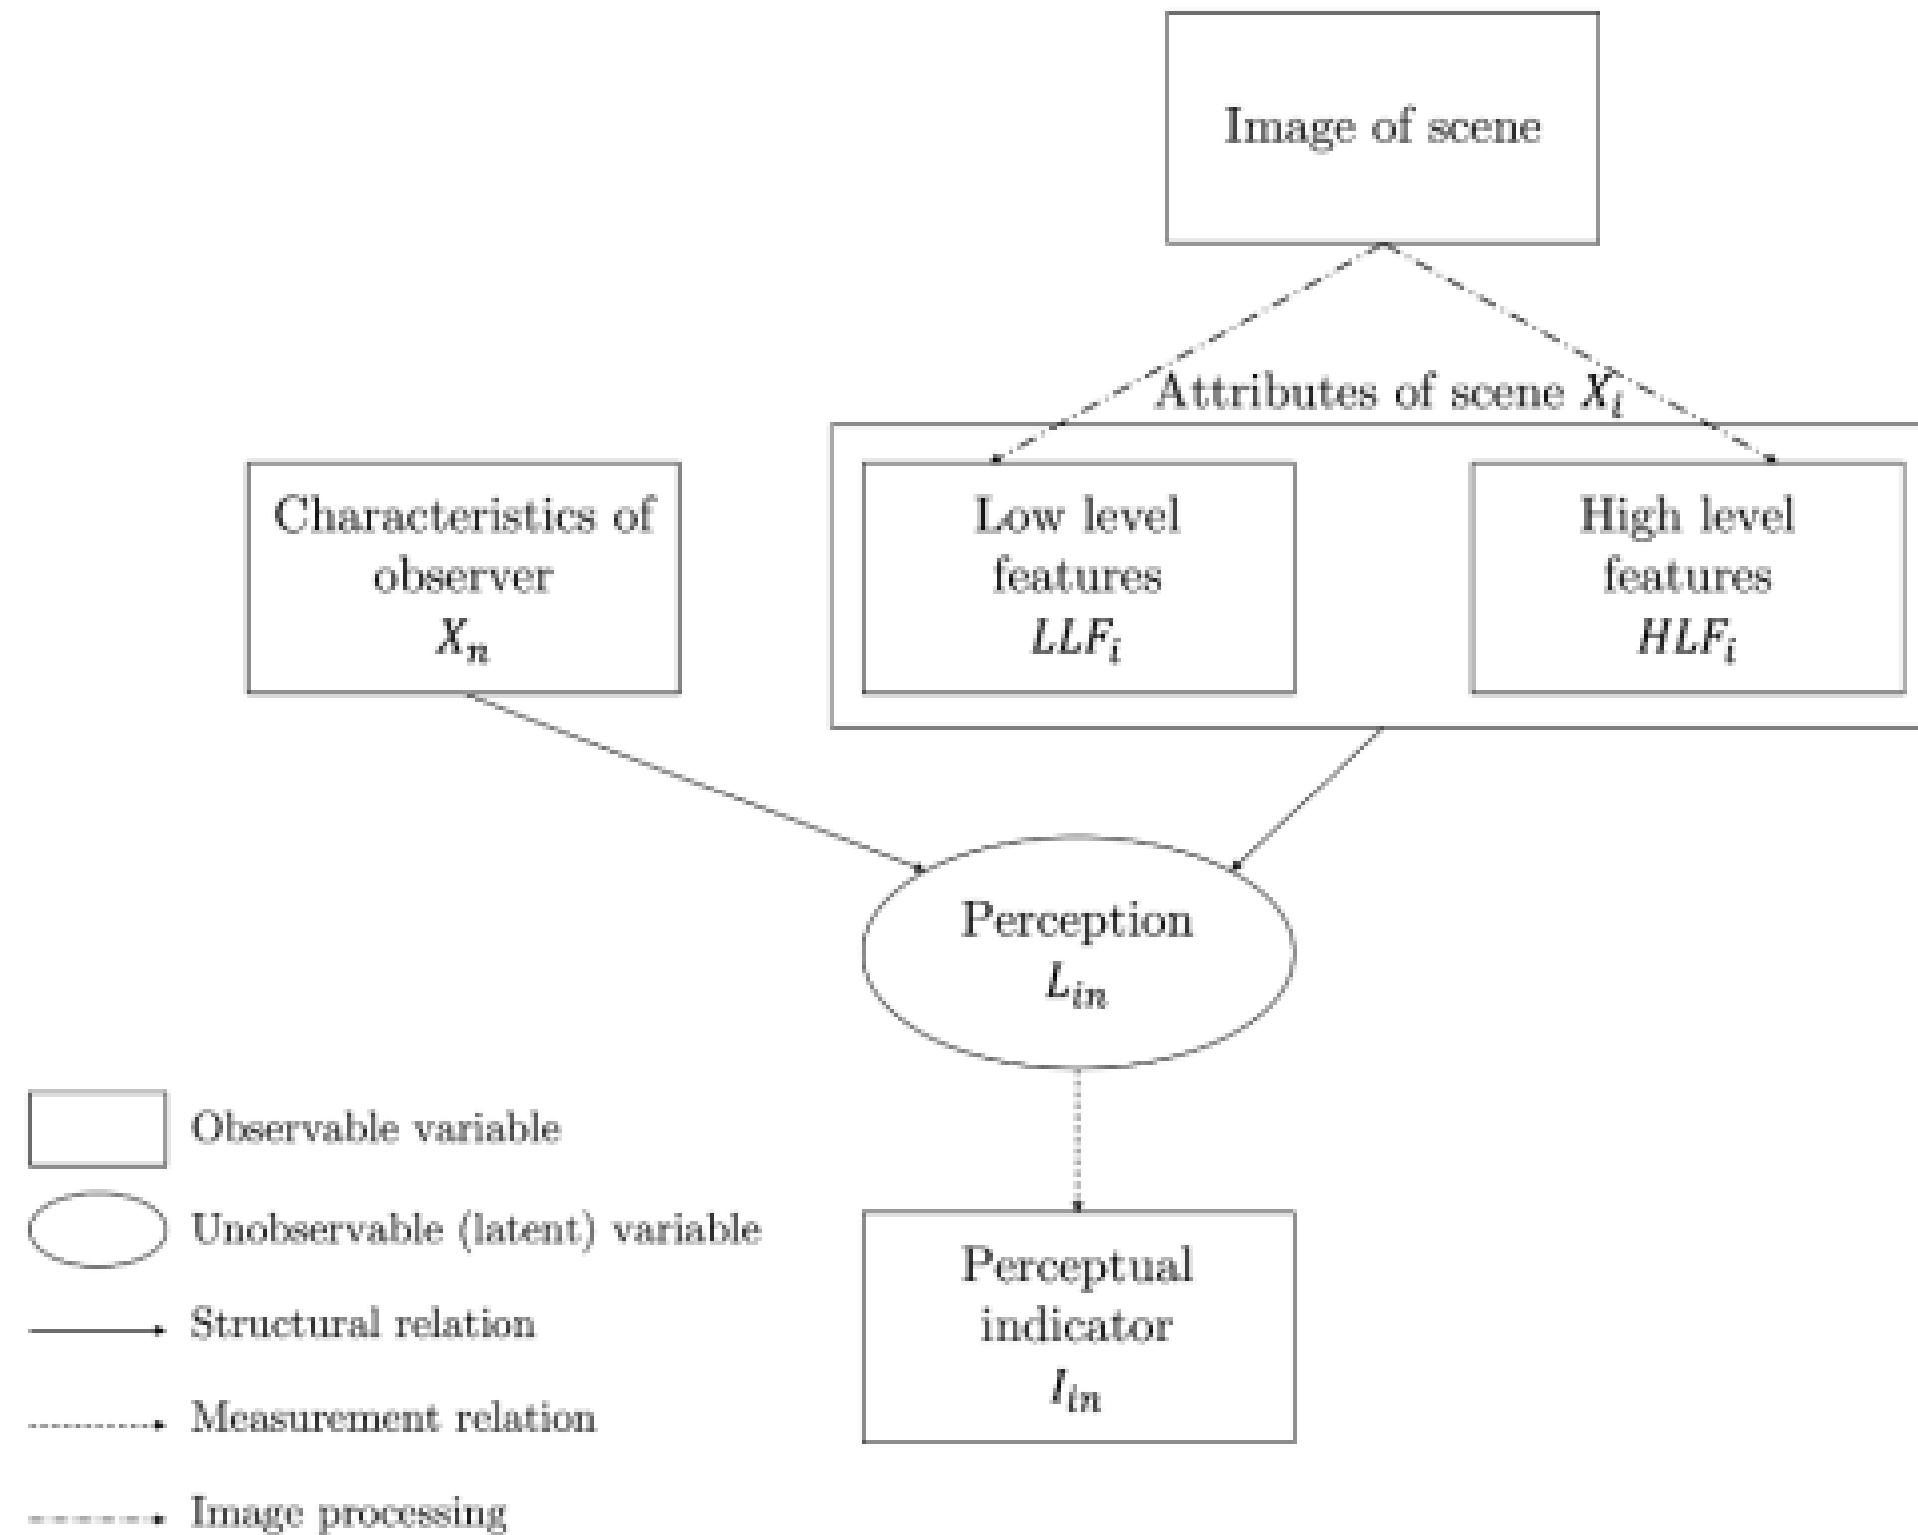


Fig. 4. Framework.



# RESULTADOS



La mayoría de los parámetros obtenidos son altamente significativos



**Table 1**  
Parameters obtained for models that quantify qualitative attributes.

	Beautiful	Boring	Depressing	Lively	Safe	Wealthy
Constant (left)	-0.0374** (-7.63)	-0.00708 (-1.27)	-0.0168** (-3.04)	-0.0378** (-9.65)	-0.0272** (-8.21)	-0.0279** (-5.38)
Building (top)	-0.0982** (-25.03)	-0.0525** (-10.64)	0.0399** (8.86)	0.0571** (16.43)	-0.0210** (-6.97)	-0.0162** (-3.63)
Building (bottom)	-0.0698** (-11.72)	0.0303** (4.74)	0.0544** (8.13)	-0.0391** (-8.22)	-0.0309** (-7.69)	-0.0477** (-7.72)
Car (top)	-0.0738** (-10.58)	0.0367** (4.59)	0.0675** (8.58)	-0.0517** (-9.15)	-0.0480** (-10.03)	-0.0935** (-12.41)
Car (bottom)		-0.0450** (-9.11)	-0.0508** (-10.15)	0.105** (28.42)	0.0637** (20.56)	0.0675** (14.06)
Cyclist (top)	0.256** (4.58)				0.133** (3.54)	0.200** (3.34)
Cyclist (bottom)	-0.0966** (-5.56)	-0.0494* (-2.42)	0.0381 (1.91)	0.0794** (5.57)	-0.0272* (-2.25)	-0.0405* (-2.14)
Fence (top)	0.0996** (17.00)	-0.0492** (-7.37)	-0.0754** (-11.46)	0.0688** (14.59)	0.0749** (18.60)	0.0919** (14.96)
Fence (bottom)	0.0485** (8.44)	-0.0543** (-8.28)	-0.0644** (-9.91)	0.0290** (6.19)	0.0147** (3.74)	
Pedestrian (top)		-0.0682** (-2.80)	-0.0687** (-2.88)	0.0595** (3.50)	0.0879** (5.98)	0.0906** (3.95)
Pedestrian (bottom)		-0.175** (-14.19)	-0.0414** (-3.30)	0.139** (15.62)	0.0200* (2.66)	-0.0321* (-2.71)
Pole (top)					-0.0184* (-2.45)	0.0330** (2.87)
Pole (bottom)	-0.0900** (-8.42)		0.0516** (4.19)	-0.0840** (-9.55)	-0.152** (-21.24)	-0.179** (-16.08)
Road (top)				-0.0185* (-2.01)		-0.0298* (-2.44)
Road (bottom)	0.113** (12.18)	-0.0241* (-2.36)	-0.118** (-11.53)	0.121** (16.06)	0.188** (29.82)	0.181** (18.44)
Sidewalk (top)	-0.104** (-10.58)	0.0589** (5.24)	0.111** (10.00)	-0.105** (-11.82)	-0.151** (-22.26)	-0.138** (-11.75)
Sidewalk (bottom)	-0.0347** (-4.52)			0.0491** (7.60)	0.0585** (10.82)	0.0461** (5.52)
Sky (top)	-0.0470** (-10.75)	0.0311** (6.09)	0.0398** (8.10)	-0.0140** (-3.94)	-0.0147** (-4.74)	-0.0313** (-6.49)
Sky (bottom)						
Traffic sign (top)	0.0894** (11.58)	-0.0453** (-5.26)	-0.0630** (-7.22)	0.0526** (8.44)	0.0480** (8.66)	0.0765** (8.82)
Traffic sign (bottom)	-0.0299** (-3.34)		0.0408** (4.07)	0.0279** (3.87)		
Vegetation (top)		-0.0183* (-2.12)		0.0301** (4.92)	0.0211** (3.98)	
Vegetation (bottom)	0.126** (24.97)	0.0474** (8.06)	-0.0856** (-14.52)	-0.0426** (-9.89)	0.0755** (20.92)	0.0554** (9.85)
Edges	6.87** (28.30)	-3.51** (-12.36)	-6.48** (-22.65)	4.76** (23.57)	4.64** (26.79)	6.07** (22.38)
Blobs		-0.00747** (-8.42)	-0.00191* (-2.17)	0.00785** (12.57)	0.00465** (8.86)	0.00616** (7.43)
Hue average	0.00350** (7.99)	-0.00149** (-3.13)	-0.00294** (-6.26)	0.000302 (0.84)	0.000674* (2.22)	0.00356** (7.68)
Saturation average	0.00252** (3.88)	0.00495** (6.64)	-0.00136 (-1.87)	-0.00253** (-4.82)	0.00197** (4.38)	0.000510 (0.73)
Lightness average	0.00108** (3.54)	0.00212** (5.60)	-0.00161** (-4.30)	0.0000444 (0.17)	0.00250** (10.98)	0.00130** (3.69)
Hue std. deviation	0.0142** (17.58)	-0.000936 (-1.03)	-0.00764** (-8.43)	0.00517** (7.95)	0.0110** (20.05)	0.00797** (9.30)
Saturation std. deviation	0.000963 (1.33)	-0.00633** (-7.64)	-0.00228* (-2.80)	0.00589** (10.10)	0.00119* (2.42)	0.00437** (5.65)
Lightness std. deviation	0.00624** (11.23)	-0.00418** (-6.57)	-0.00555** (-8.81)	0.00327** (7.28)	0.00336** (8.86)	0.00516** (8.80)
Threshold ( $\delta$ )	0.284** (152.22)	0.343** (148.38)	0.348** (150.73)	0.248** (179.00)	0.259** (216.41)	0.286** (145.25)
Number of observations	161,472	117,453	122,048	246,329	339,885	140,330
Indifference choices	12.8%	16.3%	16.2%	11.7%	12.3%	13.4%
Number of parameters	24	25	26	29	29	28
Log-likelihood	-150,814.91	-117,580.73	-120,600.49	-232,350.21	-325,593.85	-134,565.59
First preference recovery <sup>a</sup>	64.5%	59.8%	62.0%	60.7%	59.5%	61.6%
LLF likelihood ratio test <sup>b</sup>	6,370.27**	1,388.89**	2,327.71**	4,278.15**	6,772.63**	3,086.46**

"(top)" and "(bottom)" variables correspond to the upper and lower halves of the images respectively.

<sup>a</sup> Proportion of observed choices, excluding indifference choices, that have the greatest estimated utility.

<sup>b</sup> Log-likelihood ratio test statistic when comparing full model with model without high-level features. \*\*p < 0,01; \*p < 0,05.



# EJEMPLO DE RESULTADOS

**Table 1**

Parameters obtained for models that quantify qualitative attributes.

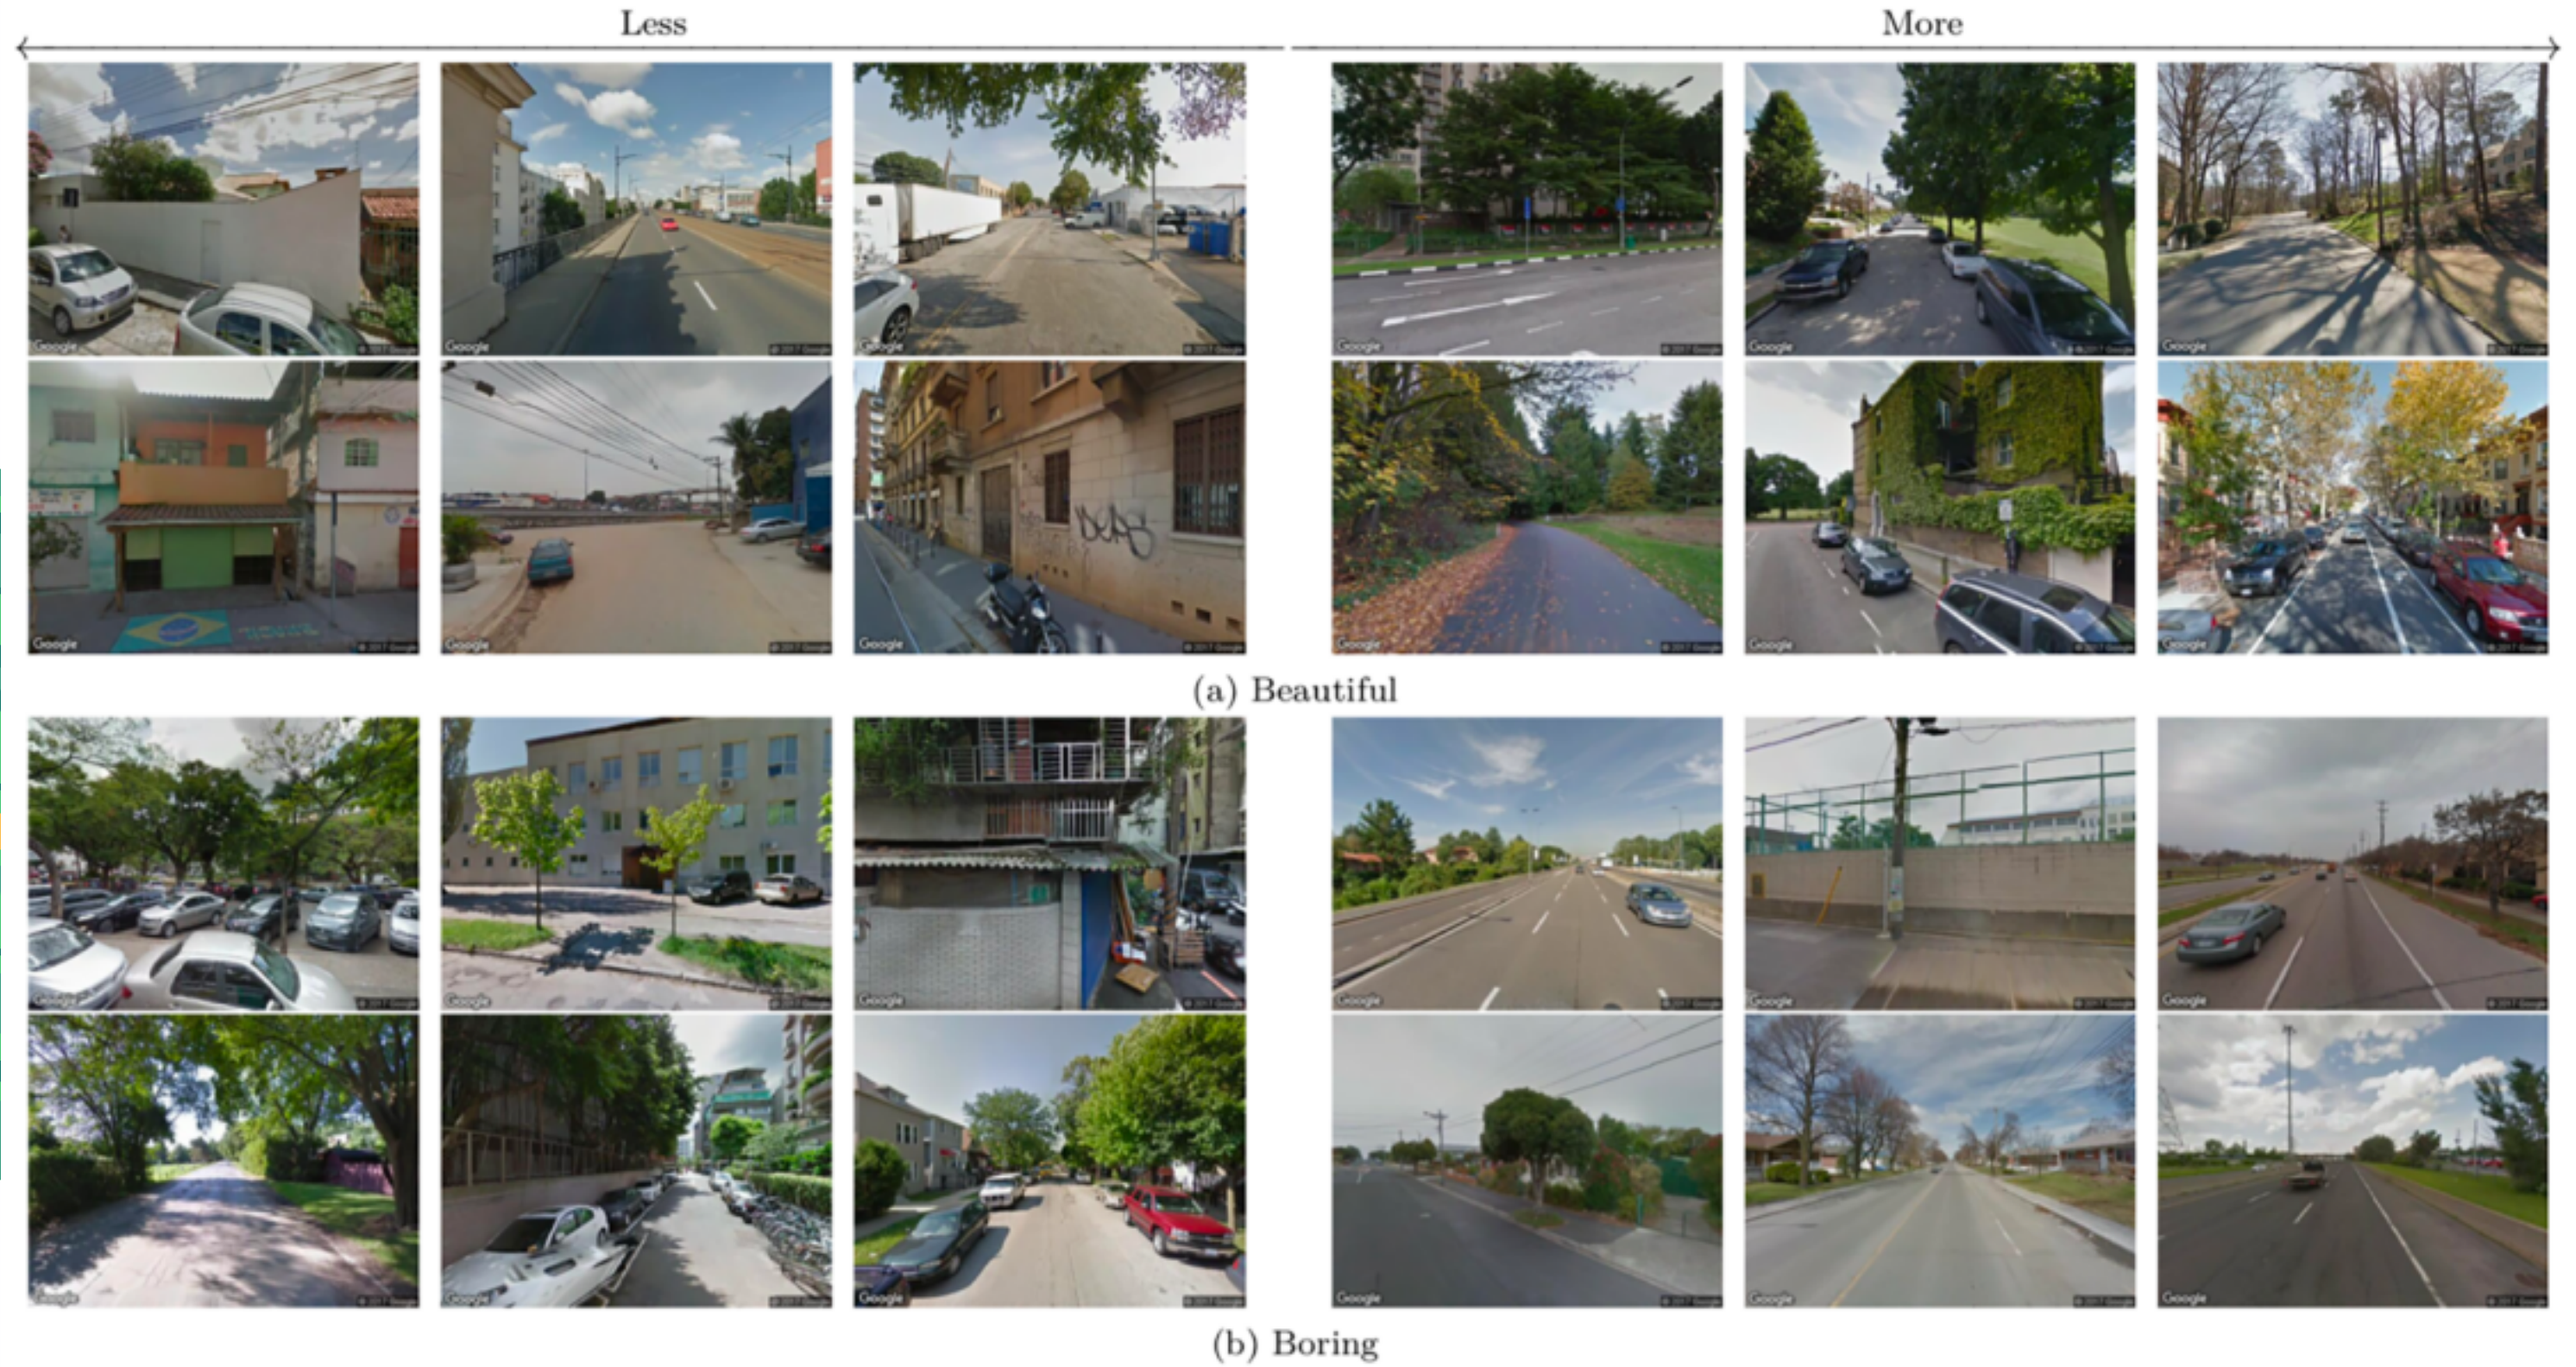
	Beautiful	Boring	Depressing	Lively	Safe	Wealthy
Constant (left)	-0.0374** (-7.63)	-0.00708 (-1.27)	-0.0168** (-3.04)	-0.0378** (-9.65)	-0.0272** (-8.21)	-0.0279** (-5.38)
Building (top)	-0.0982** (-25.03)	-0.0525** (-10.64)	0.0399** (8.86)	0.0571** (16.43)	-0.0210** (-6.97)	-0.0162** (-3.63)
Building (bottom)	-0.0698** (-11.72)	0.0303** (4.74)	0.0544** (8.13)	-0.0391** (-8.22)	-0.0309** (-7.69)	-0.0477** (-7.72)
Car (top)	-0.0738** (-10.58)	0.0367** (4.59)	0.0675** (8.58)	-0.0517** (-9.15)	-0.0480** (-10.03)	-0.0935** (-12.41)
Car (bottom)		-0.0450** (-9.11)	-0.0508** (-10.15)	0.105** (28.42)	0.0637** (20.56)	0.0675** (14.06)
Cyclist (top)	0.256** (4.58)				0.133** (3.54)	0.200** (3.34)
Cyclist (bottom)	-0.0966** (-5.56)	-0.0494* (-2.42)	0.0381 (1.91)	0.0794** (5.57)	-0.0272* (-2.25)	-0.0405* (-2.14)
Fence (top)	0.0996** (17.00)	-0.0492** (-7.37)	-0.0754** (-11.46)	0.0688** (14.59)	0.0749** (18.60)	0.0919** (14.96)
Fence (bottom)	0.0485** (8.44)	-0.0543** (-8.28)	-0.0644** (-9.91)	0.0290** (6.19)	0.0147** (3.74)	
Pedestrian (top)		-0.0682* (-2.80)	-0.0687** (-2.88)	0.0595** (3.50)	0.0879** (5.98)	0.0906** (3.95)
Pedestrian (bottom)		-0.175** (-14.19)	-0.0414** (-3.30)	0.139** (15.62)	0.0200* (2.66)	-0.0321* (-2.71)
Pole (top)					-0.0184* (-2.45)	0.0330** (2.87)
Pole (bottom)	-0.0900** (-8.42)		0.0516** (4.19)	-0.0840** (-9.55)	-0.152** (-21.24)	-0.179** (-16.08)
Road (top)				-0.0185* (-2.01)		-0.0298* (-2.44)
Road (bottom)	0.113** (12.18)	-0.0241* (-2.36)	-0.118** (-11.53)	0.121** (16.06)	0.188** (29.82)	0.181** (18.44)
Sidewalk (top)	-0.104** (-10.58)	0.0589** (5.24)	0.111** (10.00)	-0.105** (-11.82)	-0.151** (-22.26)	-0.138** (-11.75)
Sidewalk (bottom)	-0.0347** (-4.52)			0.0491** (7.60)	0.0585** (10.82)	0.0461** (5.52)
Sky (top)	-0.0470** (-10.75)	0.0311** (6.09)	0.0398** (8.10)	-0.0140** (-3.94)	-0.0147** (-4.74)	-0.0313** (-6.49)
Sky (bottom)						

**Nota:** Las cercas tuvieron un impacto positivo general en los atributos cualitativos de las imágenes.



# VALIDACIÓN

Para comprobar la validez del modelo se recuperaron las imágenes con mayor y menor percepción cuantificada:





# VALIDACIÓN

Para verificar aún más el modelo, se crearon mapas perceptuales para la ciudad de Santiago de Chile:

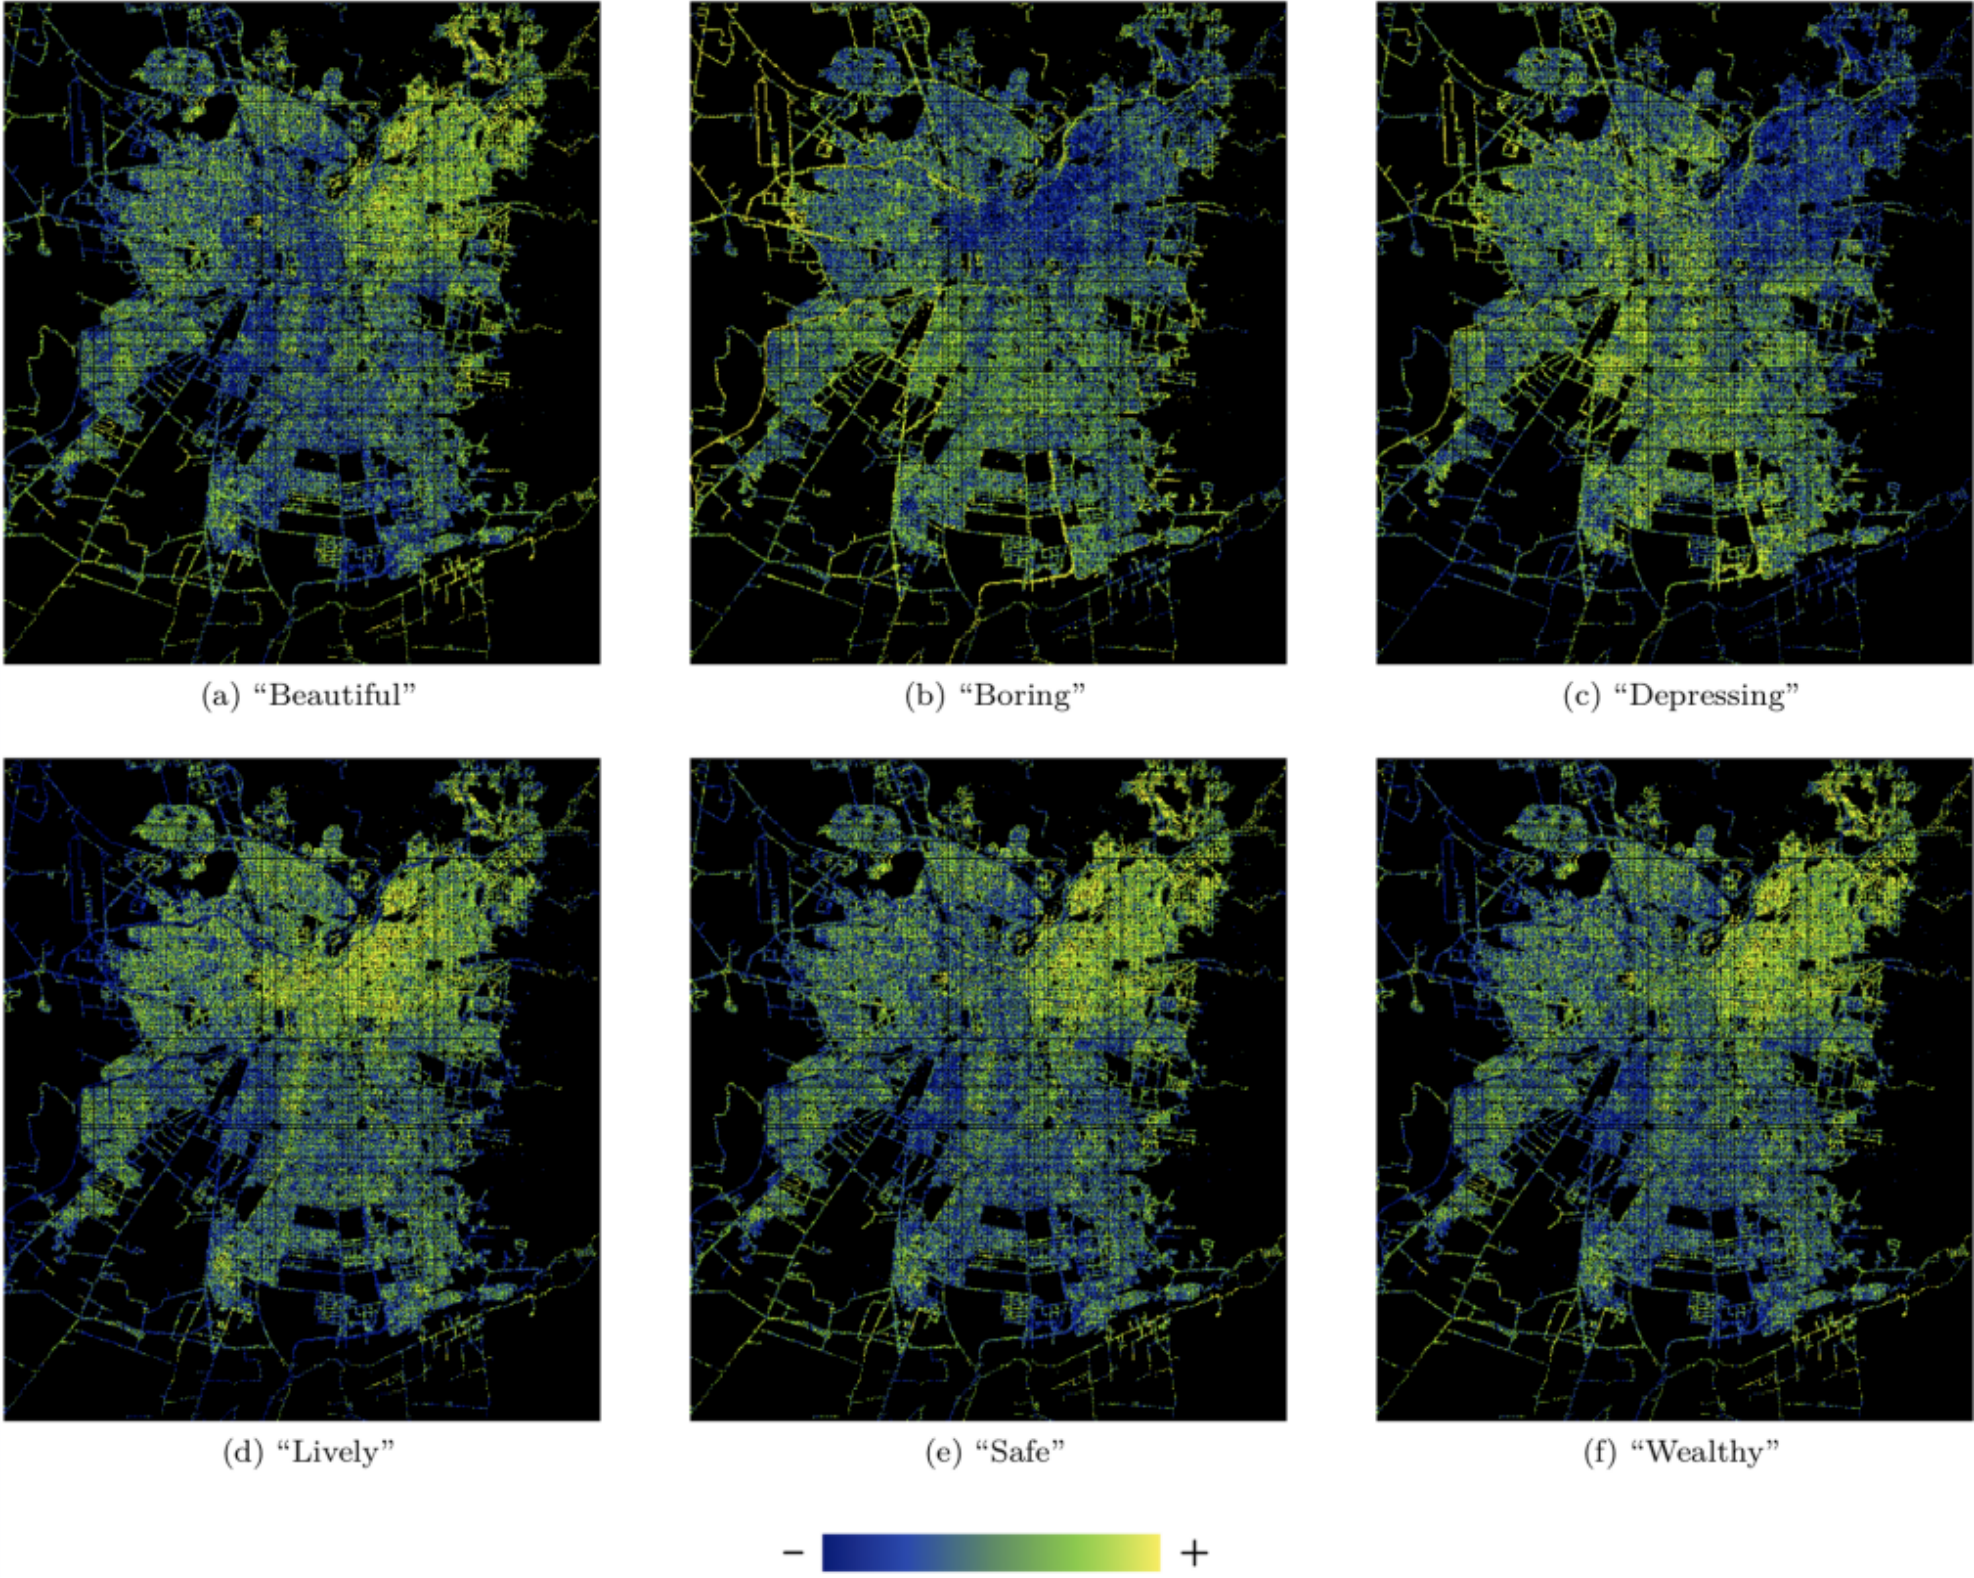



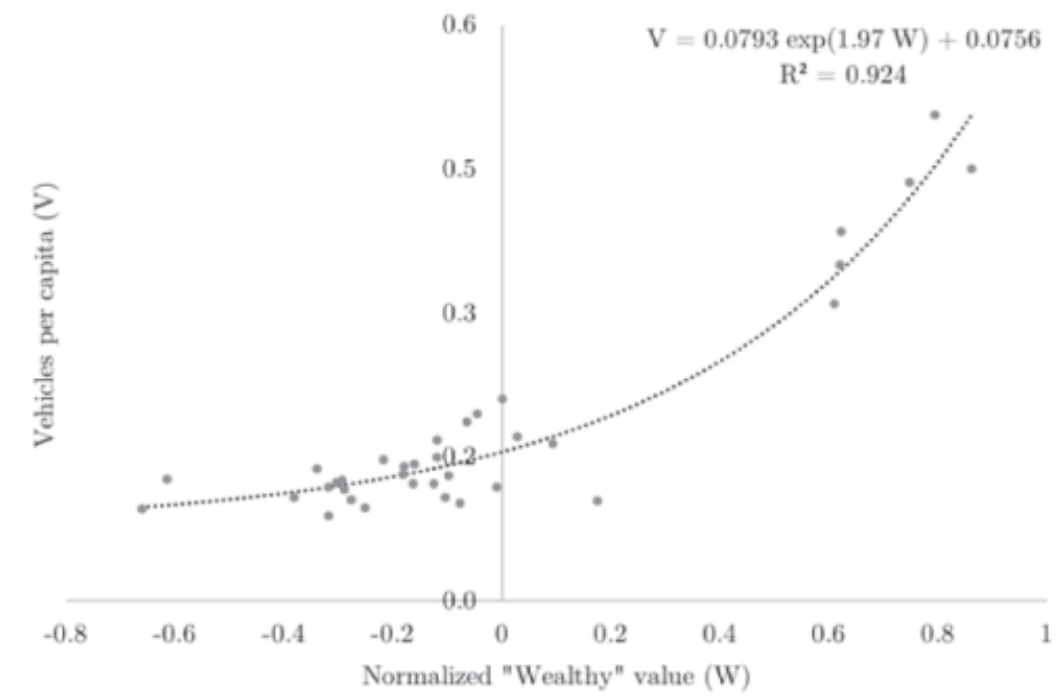
Fig. 7. Perceptual maps for Santiago, Chile.

# VALIDACIÓN

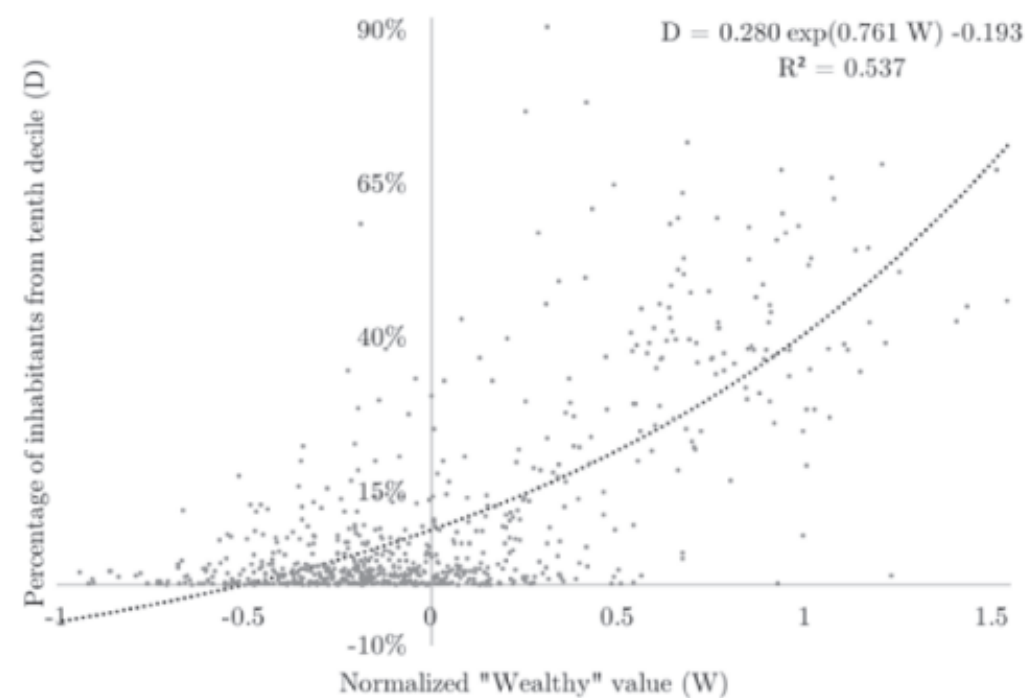
Además, se comparó la riqueza percibida con indicadores socioeconómicos:



(a)



(b)



(c)



# CONCLUSIONES



Los resultados del modelo muestran mayores capacidades explicativas a los modelos utilizados anteriormente en la literatura.



Este modelo tiene un gran potencial y puede ayudar a investigadores y a la planificación de políticas públicas.



La propuesta metodológica es muy útil, dado a que se puede utilizar por las **municipalidades** para identificar áreas que requieren mejoras a un **bajo costo**.



# LIMITACIONES

1

Solo se consideran las características bidimensionales y no las características tridimensionales.

2

No se consideran otros factores que pueden afectar a esas percepciones como la presencia de servicios públicos.

3


Place Pulse utiliza no tiene información sobre las características de los(as) encuestados(as).






## REFLEXIONES / PREGUNTAS

Perspectiva  
urbana




¿Qué sucede con las zonas rurales?

¿Podríamos intervenir el medio como  
proyecto de salud mental?



¿Y como proyecto de seguridad?

¿Fueron informados los encuestados de  
que, tanto sus respuestas, como su  
geolocalización serían utilizadas para el  
estudio?



Si no lo fueron, es esto ético?





Javiera Celedón | Macarena Jiménez | Ximena Rifo | Yerko Sanhueza | Tamara San Martín