



Análisis de heterogeneidad en la percepción de espacios públicos utilizando algoritmos de inteligencia artificial y modelos de elección discreta

Tomás Ramírez

Tomás Rossetti - Hans Lobel - Ricardo Hurtubia

Departamento de Ingeniería de Transporte y Logística
Departamento de Ciencia de la Computación
Centro de Desarrollo Urbano Sustentable
Instituto Milenio Fundamento de los Datos

Pontificia Universidad Católica de Chile

Al mirar estas imágenes, ¿Cuál es un mejor barrio para vivir?



El diseño de la ciudad no solo debe ser funcional, sino que además carga un alto significado emocional en quienes la observan.

Arquitectura

*This image has wide **practical** and **emotional** importance to the individual.*

- Lynch, K. (1960)

Geografía humana

La experiencia de conocer un lugar está principalmente relacionado con **la vista** y es enriquecido por los otros sentidos. Luego es cargada de **emociones y pensamientos** que entregan una connotación al espacio.

- Tuan, Y. (1977)

Geografía

El único marco conceptual adecuado para comprender los fenómenos urbanos es aquel que toma sus fundamentos tanto de la **imaginación sociológica** como de la **geografía**.

- Harvey, D. (1979).

Lynch, K. (1960). The image of the city.

Harvey, D. (1979). Urbanismo y desigualdad social.

Tuan, Y. (1977). Space and place: the perspective of experience.

AGENDA

- I REVISIÓN BIBLIOGRÁFICA
- II DESAFÍOS PENDIENTES
- III METODOLOGÍA
- IV RESULTADOS

¿Cómo medir la percepción?

En resumen, hay 4 corrientes metodológicas en la literatura

- 1) **Metodologías cualitativas**
- 2) **Preferencias declaradas**
- 3) **Modelos de Aprendizaje Automático**
- 4) **Modelos híbridos**

1) Metodologías cualitativas

Encuestas y entrevistas presenciales

FIG. 2. Outline map of the Boston peninsula

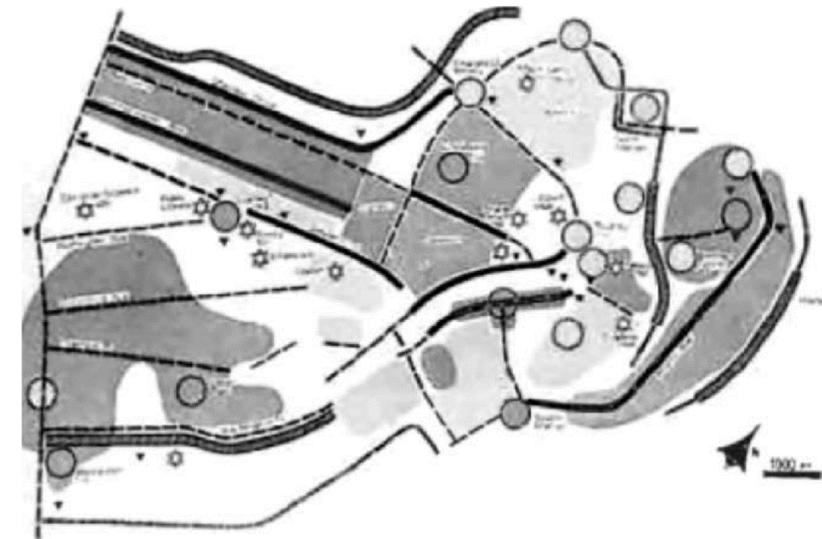
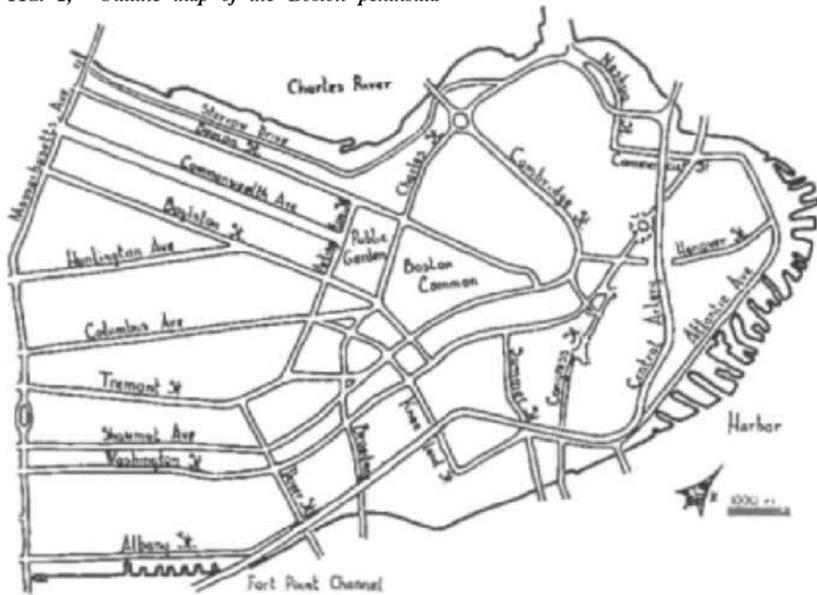
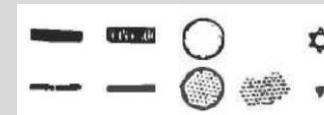


FIG. 3. The visual form of Boston as teen in the field

Leyenda



paths, edges, nodes, regions and landmarks

2) Encuestas PD

Encuestas con escenarios ficticios controlados por el modelador.



Variables	Niveles
Transparencia	0%, 15%, 60%, 80%
Estacionamientos	Si, no
Vegetación	Si, no
Peatones	Pocos, Algunos
Ancho de la vereda	Angosta, ancha
Color de la fachada	Saturado, claros

128 posibles escenarios
16 escogidos mediante diseño ortogonal

3) Aprendizaje automático

Algoritmos predictivos entrenados por grandes cantidad de evaluaciones de imágenes realizadas por humanos.



* $0 \leq Q \leq 10$

Quercia, O'hare & Cramer (2014). *Aesthetic Capital: What Makes London Look Beautiful, Quiet, and Happy?*

3) Aprendizaje automático

Encuestas on-line de percepciones han generado grandes bases de datos para entrenar algoritmos predictivos.

Which place looks safer ? ▾

Which place looks **safer**?

Which place looks **livelier**?

Which place looks **more boring**?

Which place looks **wealthier**?

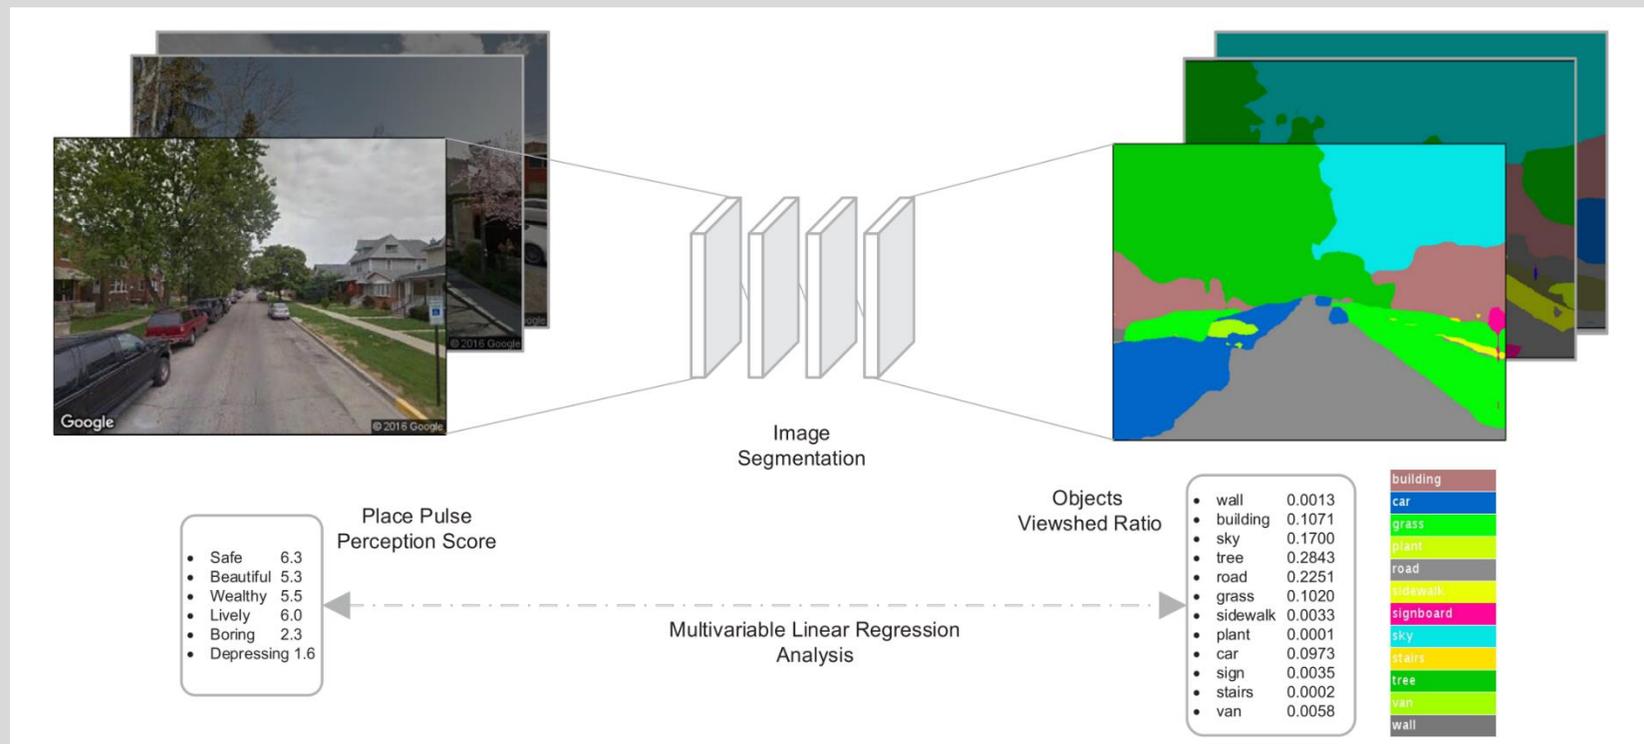
Which place looks **more depressing**?

Which place looks **more beautiful**?

←
=
→

4) Metodologías híbridas

Uso de aprendizaje automático para determinar las variables explicativas del modelo y el uso de modelos econométricos para explicar las preferencias.



Zhang et al. (2018). Measuring human perceptions of a large-scale urban region using machine learning.

Coburn et al. (2019). Psychological responses to natural patterns in architecture.

Rossetti et al. (2019). Explaining subjective perceptions of public spaces as a function of the built environment: A massive data approach.

¿Cómo medir la percepción?

En resumen, hay 4 corrientes metodológicas en la literatura

- 1) **Metodologías cualitativas, pero poco escalables**
- 2) **Preferencias declaradas, con escenarios controlados**
- 3) **Modelos de Aprendizaje automático, pero poco interpretables**
- 4) **Modelos híbridos**

AGENDA



ANÁLISIS DE ESPACIOS PÚBLICOS



DESAFÍOS PENDIENTES



METODOLOGÍA



RESULTADOS

- a** **Buscar heterogeneidad en la percepción de espacios públicos**

- b** **Avanzar hacia una mejor representación de las imágenes**

Wekun: Nueva base de datos

Explorar diferencias sociodemográficas

The screenshot shows a web browser window with the Wekun website. The browser's address bar shows the URL `wekun.ing.puc.cl/survey`. The website has a red header with the Wekun logo and language options for Spanish and English. The main content area features a survey question: "¿Cuál le parece un lugar más bonito?" (Which one do you think is a nicer place?). Below the question are two side-by-side Google Street View images. The left image shows a wide, open road with trees and a cloudy sky. The right image shows a narrow, urban street with tall buildings and parked cars. Between the images are two circular buttons: one with an equals sign (=) and one with an X. At the bottom of the survey area, there is a note: "★ La cantidad de imágenes es infinita, por lo que cuando no quieras evaluar más lugares solo debes cerrar la página. ¡Gracias por ayudarnos!" (★ The number of images is infinite, so when you don't want to evaluate more places you just have to close the page. Thank you for helping us!). A footer contains navigation links: Encuesta, Instrucciones, Nuevo Usuario, Qué es Wekun, and Nuestro Equipo.

Wekun: Nueva base de datos

Explorar diferencias sociodemográficas

The image shows a web browser window displaying the registration page for Wekun. The browser's address bar shows the URL `wekun.ing.puc.cl/register`. The page has a dark theme with a red header bar. The main content area is titled "Datos personales" and contains several input fields: "Sexo" with radio buttons for "M", "F", and "Otro"; "Edad" with a text input field; "Nacionalidad", "País de Residencia", "Región de Residencia", "Mayor nivel Educativo que ha cursado", and "Principal medio de transporte que utiliza", all with dropdown menus. At the bottom of the form are two buttons: "INSTRUCCIONES" (grey) and "COMENZAR" (red). A footer navigation bar contains links for "Encuesta", "Instrucciones", "Nuevo Usuario", "Qué es Wekun", and "Nuestro Equipo".

Wekun Español English

Datos personales

Sexo M F Otro

Edad

Nacionalidad

País de Residencia

Región de Residencia

Mayor nivel Educativo que ha cursado

Principal medio de transporte que utiliza

[INSTRUCCIONES](#) [COMENZAR](#)

[Encuesta](#) | [Instrucciones](#) | [Nuevo Usuario](#) | [Qué es Wekun](#) | [Nuestro Equipo](#)

Wekun: Nueva base de datos

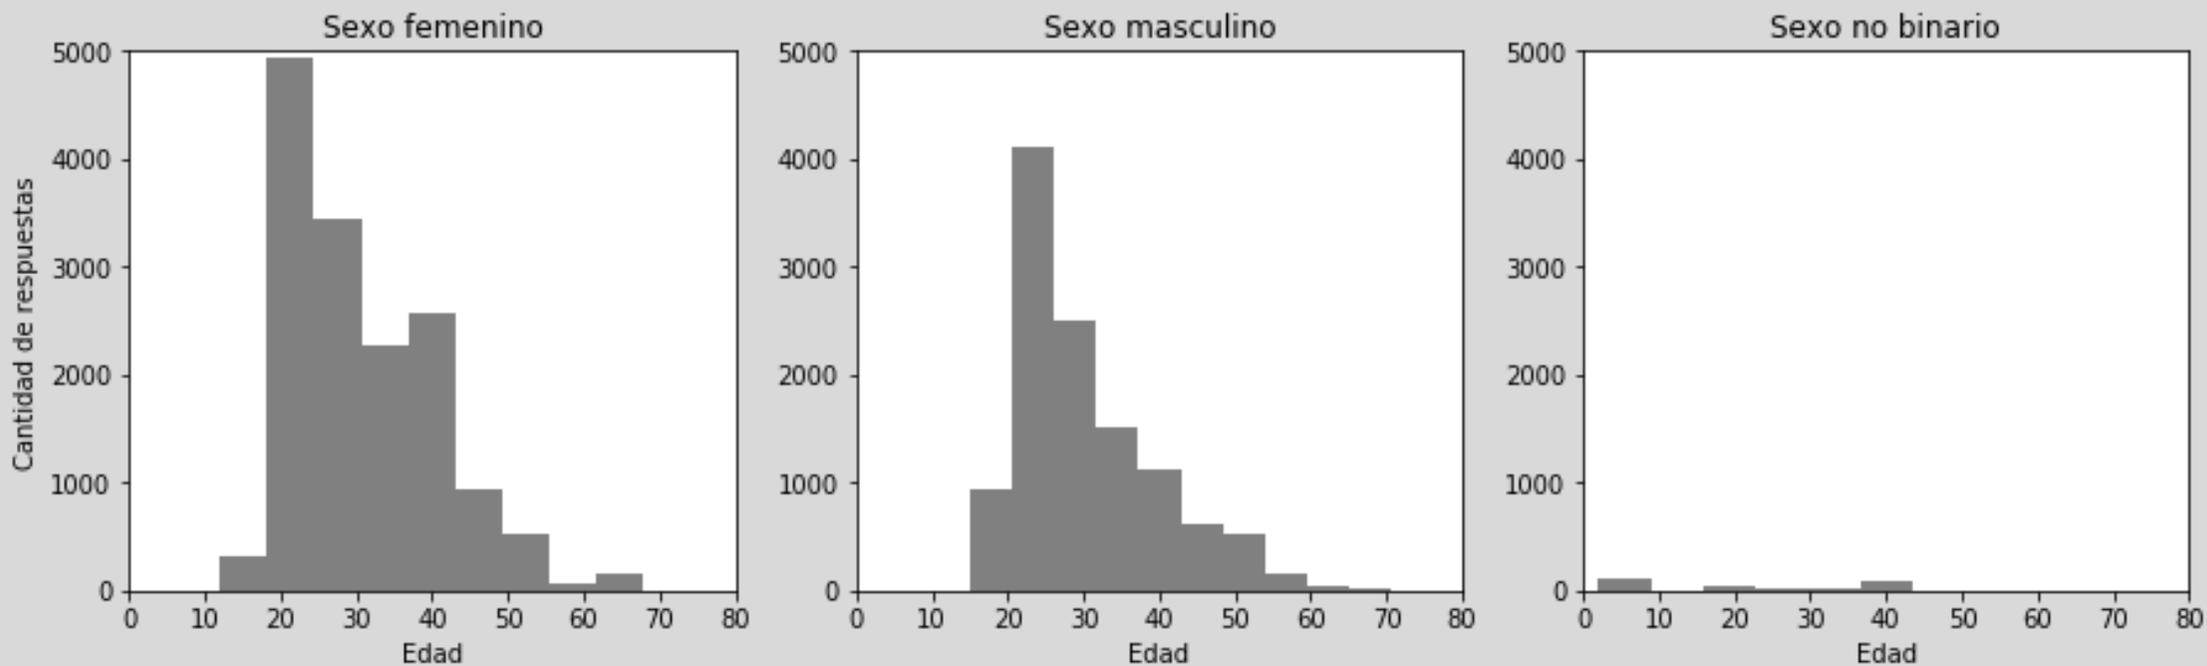
CANTIDAD DE OBSERVACIONES POR MODELO

	Total	Hombre*	Mujer*	Otro
Caminar	7.794	56,9%	41,5%	1,6%
Vivir	5.609	60,3%	39,4%	0,4%
Seguro	4.285	59,0%	39,7%	1,3%
Bonito	5.417	51,7%	47,1%	1,2%
Adinerado	3.982	52,6%	46,7%	0,7%
Total	27.087	56,3%	42,6%	1,1%

* Cantidad de observaciones

Wekun: Nueva base de datos

HISTOGRAMA DE OBSERVACIONES POR SEXO Y EDAD



Parametrización de la imagen

Uso de algoritmo de Detección de Objetos, para complementar la información obtenida con el Segmentador Semántico



AGENDA



ANÁLISIS DE ESPACIOS PÚBLICOS



DESAFÍOS PENDIENTES



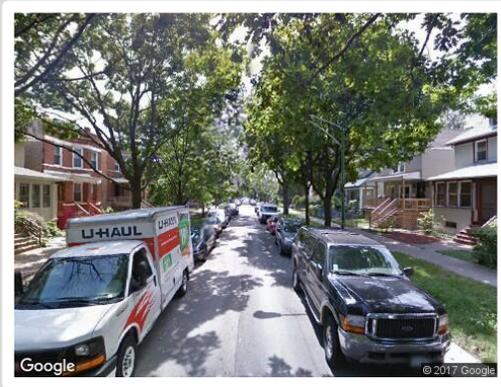
METODOLOGÍA



RESULTADOS

Función de Utilidad

Para cada imagen



$$U_i = \sum_r \theta_r \cdot X_{i,r} + \varepsilon_i, \quad i \in \{1, 2\}$$

θ_r : efecto marginal del atributo r

$X_{i,r}$: atributo r de la imagen i

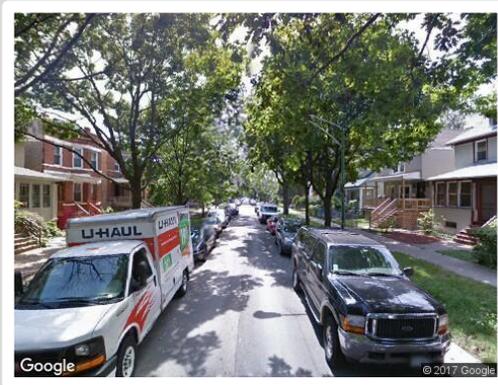
ε_i : componente de error

Atributos:

- Luminosidad, saturación y exposición
- Segmentación Semántica
- Detección de Objetos

Función de Utilidad

Para cada imagen



$$U_i = \sum_r \theta_r \cdot X_{i,r} + \varepsilon_i, \quad i \in \{1, 2\}$$

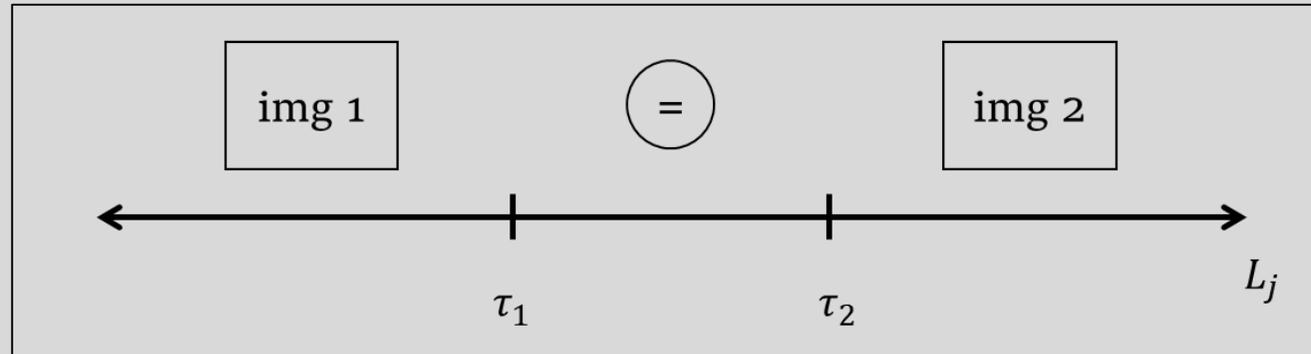
$$L_j = U_2 - U_1$$

Para cada par de imágenes



$$L_j = \sum_r \theta_r (X_{2,r} - X_{1,r}) + \varepsilon_2 - \varepsilon_1$$

Logit Ordinal



$$P_1 = 1 - \frac{1}{1 + \exp(-\mu(L_j - \tau_1))}$$

$$P_e = \frac{1}{1 + \exp(-\mu(L_j - \tau_1))} - \frac{1}{1 + \exp(-\mu(L_j - \tau_2))}$$

$$P_2 = \frac{1}{1 + \exp(-\mu(L_j - \tau_2))}$$

AGENDA



ANÁLISIS DE ESPACIOS PÚBLICOS



DESAFÍOS PENDIENTES



METODOLOGÍA



RESULTADOS

Segmentador semántico

Parameters	Caminar		Vivir	
HLF N: Bicyclist	5,5267	(2,01)		
HLF N: Building				
HLF N: Car	-1,1298	(-3,30)		
HLF N: Fence	1,1886	(4,19)	1,0433	(3,18)
HLF N: Pavement	-2,1381	(-4,50)		
HLF N: Pedestrian				
HLF N: Pole			-1,5846	(-2,65)
HLF N: Road			-1,8265	(-2,60)
HLF N: SignSymbol	0,8884	(2,50)	1,1168	(2,49)
HLF N: Sky	-0,4572	(-2,15)		
HLF N: Tree	1,1341	(3,18)	0,8900	(2,10)
HLF S: Bicyclist				
HLF S: Building	-1,0491	(-3,82)		
HLF S: Car				
HLF S: Fence	0,7280	(2,62)	1,6312	(5,06)
HLF S: Pavement	1,1324	(3,01)		
HLF S: Pedestrian				
HLF S: Pole	-2,4470	(-5,08)	-1,8386	(-3,26)
HLF S: Road	2,1157	(4,76)	4,6478	(9,58)
HLF S: SignSymbol				
HLF S: Sky				
HLF S: Tree	1,8138	(7,10)	2,4197	(8,88)

Parámetros de corrección

Parameters	Caminar		Vivir	
LLF: edges	9,0950	(7,73)	8,9381	(6,76)
LLF: mean_h	0,0042	(1,94)	0,0018	(0,79)
LLF: mean_l	-0,0008	(-0,52)	0,0033	(1,87)
LLF: mean_s	0,0032	(1,03)	0,0075	(2,34)
LLF: stdev_h	0,0050	(1,28)	0,0190	(4,10)
LLF: stdev_l	0,0053	(1,98)	0,0077	(2,60)
LLF: stdev_s	0,0116	(3,35)	0,0092	(2,26)
OD: car	0,1655	(4,38)	0,3131	(5,61)
LAMBDA: car	0,3075	(3,46)	0,2977	(4,05)
OD: person	0,0967	(6,35)	0,0463	(2,67)
OD: bike	0,1091	(1,95)		
OD: truck	-0,1061	(-4,13)	-0,1579	(-5,41)
delta2	0,8198	(37,77)	0,8194	(31,57)
tau1	-0,4084	(-15,89)	-0,4561	(-14,69)
Log-verosimilitud	-6966,85		-4788,82	
N Parameters	32		31	

Detección de objetos

Parameters	Caminar		Vivir	
LLF: edges	9,0950	(7,73)	8,9381	(6,76)
LLF: mean_h	0,0042	(1,94)	0,0018	(0,79)
LLF: mean_l	-0,0008	(-0,52)	0,0033	(1,87)
LLF: mean_s	0,0032	(1,03)	0,0075	(2,34)
LLF: stdev_h	0,0050	(1,28)	0,0190	(4,10)
LLF: stdev_l	0,0053	(1,98)	0,0077	(2,60)
LLF: stdev_s	0,0116	(3,35)	0,0092	(2,26)
OD: car	0,1655	(4,38)	0,3131	(5,61)
LAMBDA: car	0,3075	(3,46)	0,2977	(4,05)
OD: person	0,0967	(6,35)	0,0463	(2,67)
OD: bike	0,1091	(1,95)		
OD: truck	-0,1061	(-4,13)	-0,1579	(-5,41)
delta2	0,8198	(37,77)	0,8194	(31,57)
tau1	-0,4084	(-15,89)	-0,4561	(-14,69)
Log-verosimilitud	-6966,85		-4788,82	
N Parameters	32		31	

No linealidades: Conteo de objetos

$$L_j = \sum_r \theta_r \cdot X_{r,j} + \beta \cdot X_{k,j}(\lambda) + \varepsilon_j$$

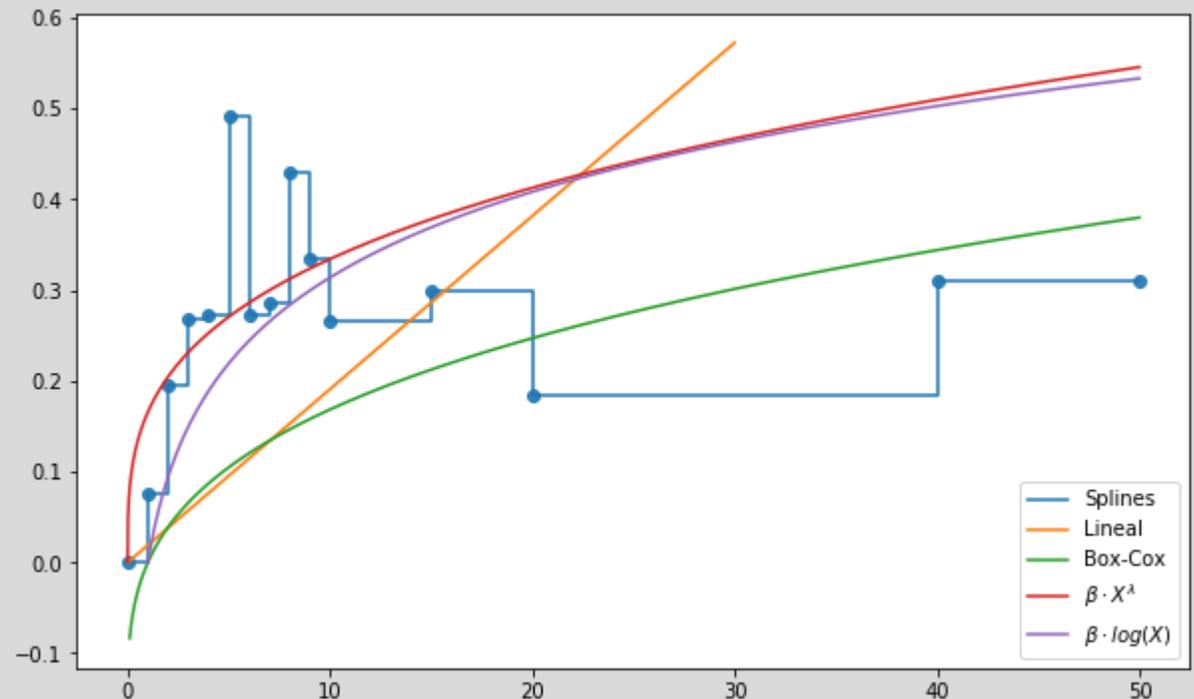
Transformación Box-Cox

$$X_{k,j}(\lambda) = \begin{cases} \frac{X^\lambda - 1}{\lambda}, & \text{si } \lambda \neq 0 \\ \ln X, & \text{si } \lambda = 0 \end{cases}$$

No lineal: exponente λ

$$X_{k,j}(\lambda) = X^\lambda$$

TRANSFORMACIONES VARIABLE AUTOMÓVIL



Heterogeneidad en la percepción

Parameters	Caminar	Vivir
PED + BIKE w/ HLF: Building N	0,6667 (2,33)	1,1615 (3,23)
CAR w/ HLF: Pedestrian N	3,7321 (1,83)	-3,2445 (-2,06)
PED + BIKE w/ HLF: Pedestrian S	3,3850 (3,71)	
CAR w/ HLF: Road N		-0,20 (-0,14)
TP w/ OD: bike		0,20 (2,65)
PED + BIKE w/ OD: car		-0,16 (-2,56)
Female w/ HLF: Bicyclist S	-0,1433 (-2,08)	2,3577 (3,25)
Female w/ HLF: Pavement S		0,3339 (2,83)
Female w/ HLF: SignSymbol N		-0,3364 (-2,22)
Female w/ OD: truck	0,0047 (2,16)	

Variación Sistemática de gustos

$$L_j = \sum_r \theta_r \cdot X_{r,j} + \left(\theta_k + \sum_w \theta_w \cdot \delta_m \right) X_{k,j} + \varepsilon_j$$

Conclusiones

- 1) **Las nuevas variables incorporadas (heterogeneidad, conteo de objetos) son relevantes en la modelación y permiten avanzar hacia modelos interpretables.**
- 2) Estamos modelando decisiones muy complejas y al no tener un diseño experimental, hay mucho ruido que es necesario tener en cuenta antes de enunciar conclusiones generalizables.
- 3) Entrenar un segmentado semántico y detector de objetos en base al tipo de imágenes que estamos utilizando ayudaría a reducir ese ruido.
- 4) Esperamos que un mayor tamaño muestral facilite el proceso de modelamiento.
- 5) En la medida que la IA avance seremos capaces de detectar más variables que describan la imagen que complementen estos modelos.

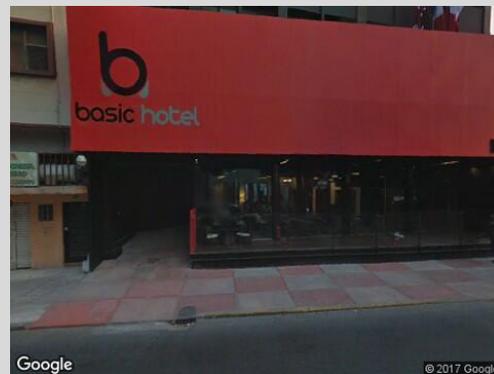
Conclusiones

- 1) Las nuevas variables incorporadas (heterogeneidad, conteo de objetos) son relevantes en la modelación y permiten avanzar hacia modelos interpretables.
- 2) **Estamos modelando decisiones muy complejas y al no tener un diseño experimental, hay mucho ruido que es necesario tener en cuenta antes de enunciar conclusiones generalizables.**
- 3) Entrenar un segmentado semántico y detector de objetos en base al tipo de imágenes que estamos utilizando ayudaría a reducir ese ruido.
- 4) Esperamos que un mayor tamaño muestral facilite el proceso de modelamiento.
- 5) En la medida que la IA avance seremos capaces de detectar más variables que describan la imagen que complementen estos modelos.

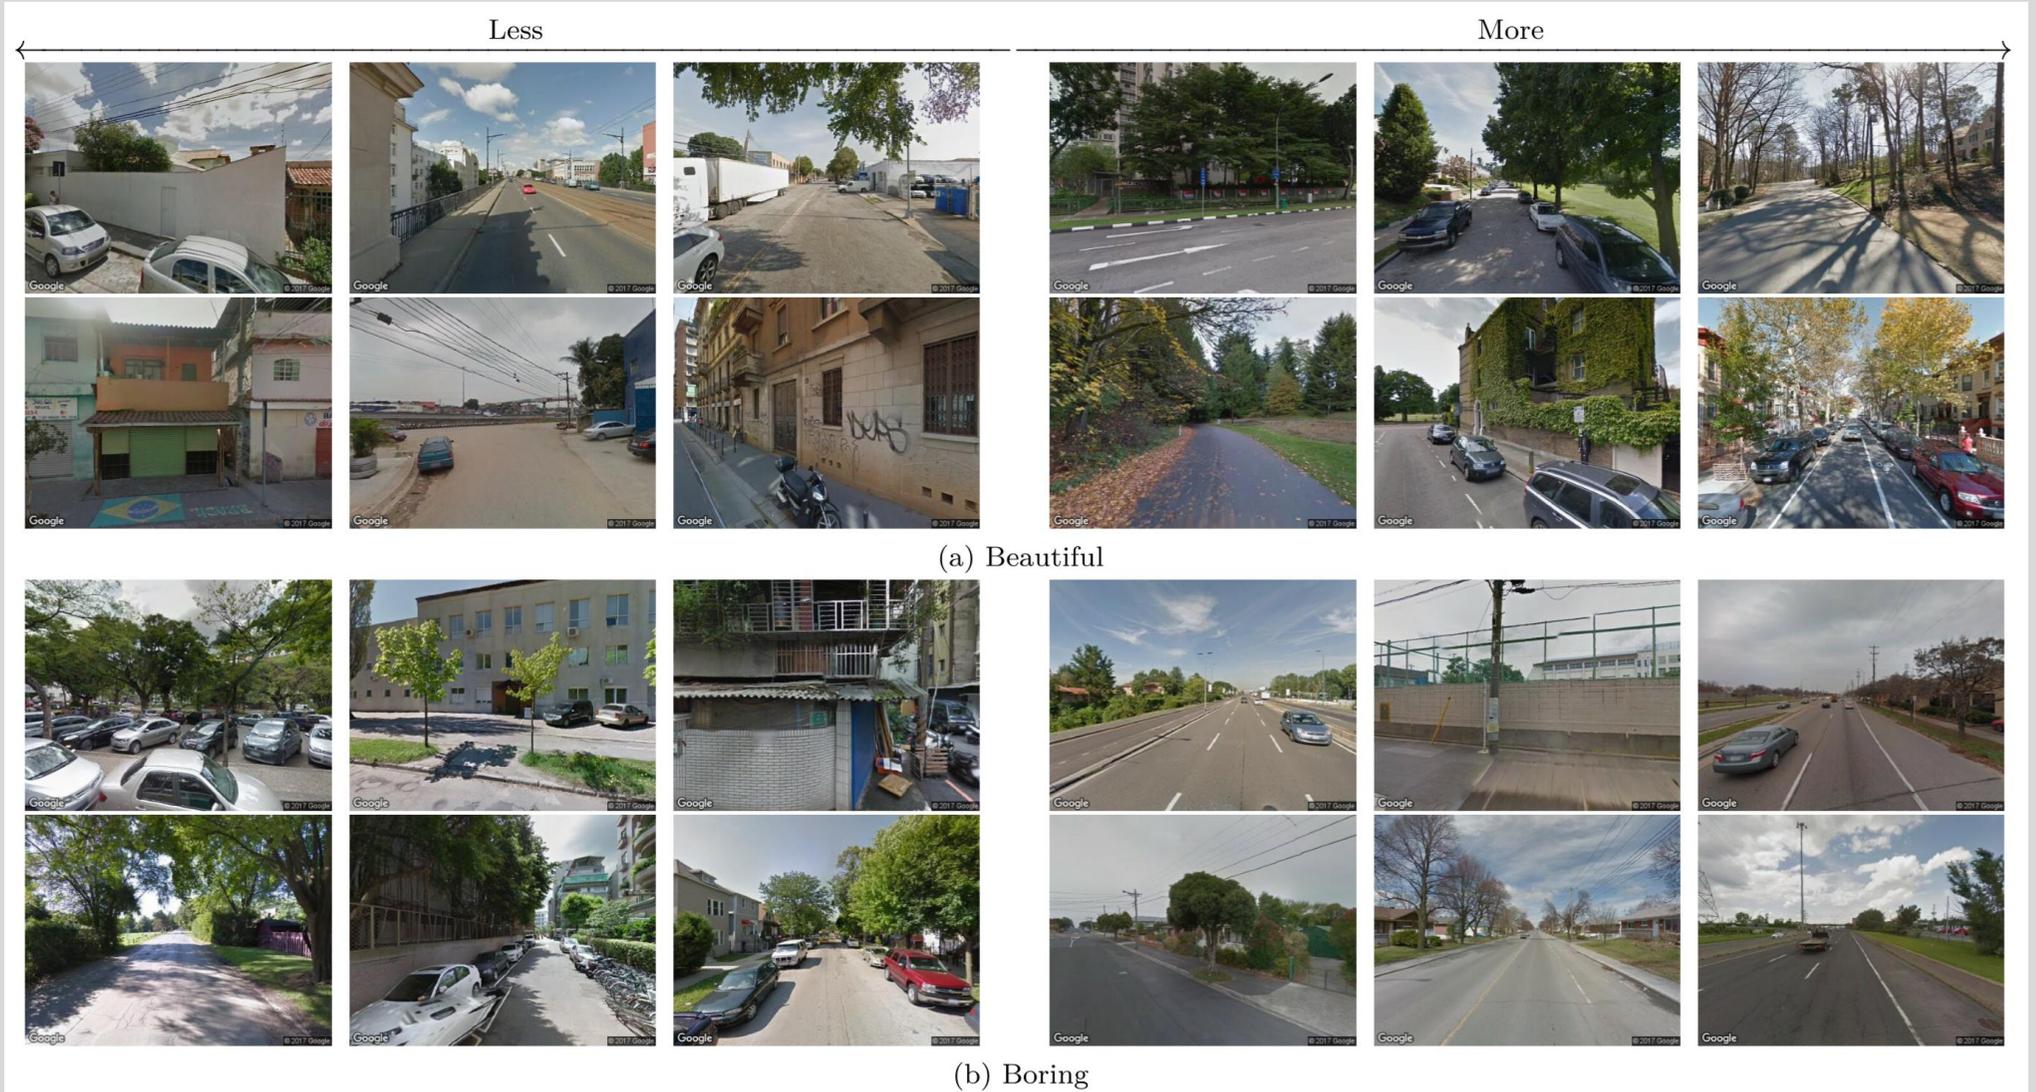
Conclusiones

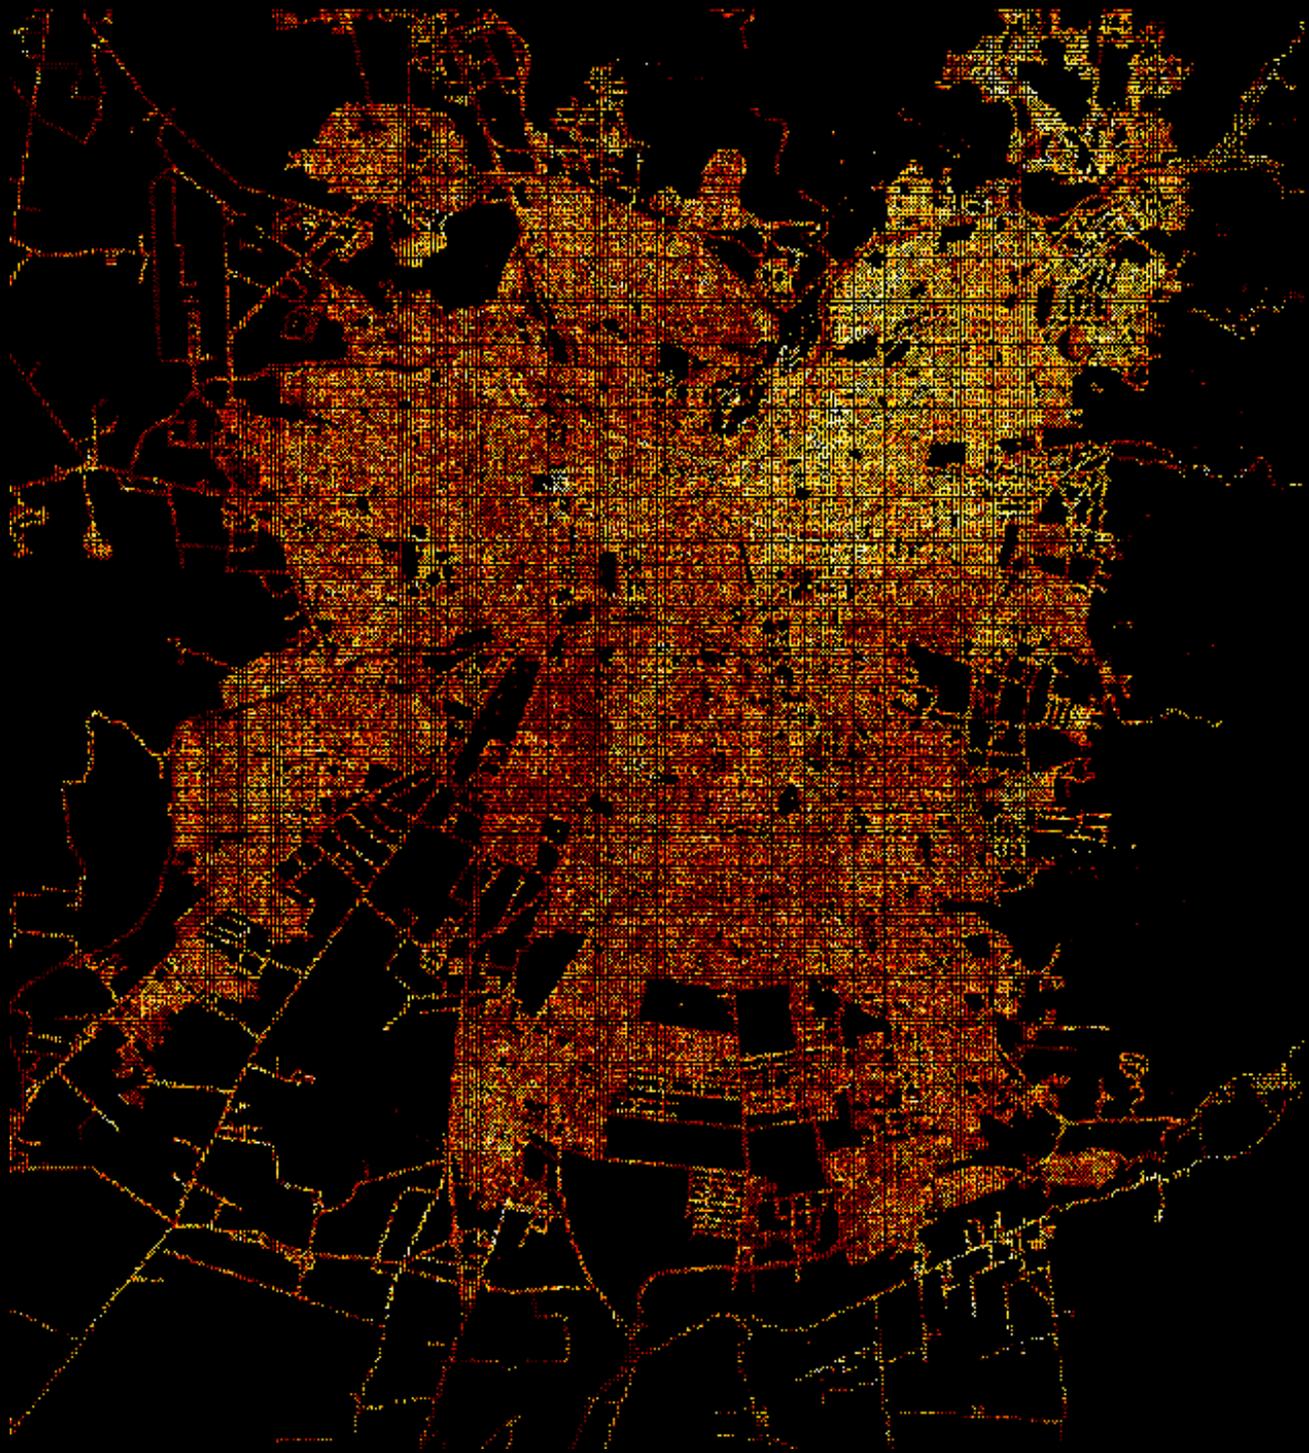
- 1) Las nuevas variables incorporadas (heterogeneidad, conteo de objetos) son relevantes en la modelación y permiten avanzar hacia modelos interpretables.
- 2) Estamos modelando decisiones muy complejas y al no tener un diseño experimental, hay mucho ruido que es necesario tener en cuenta antes de enunciar conclusiones generalizables.
- 3) **Entrenar un segmentado semántico y detector de objetos en base al tipo de imágenes que estamos utilizando ayudaría a reducir ese ruido.**
- 4) Esperamos que un mayor tamaño muestral facilite el proceso de modelamiento.
- 5) En la medida que la IA avance seremos capaces de detectar más variables que describan la imagen que complementen estos modelos.

TOP 12 AUTOMÓVIL MITAD SUPERIOR SEGÚN SEGNET



PREDICCIONES DE VARIABLES SUBJETIVAS ROSSETTI ET AL. (2019)

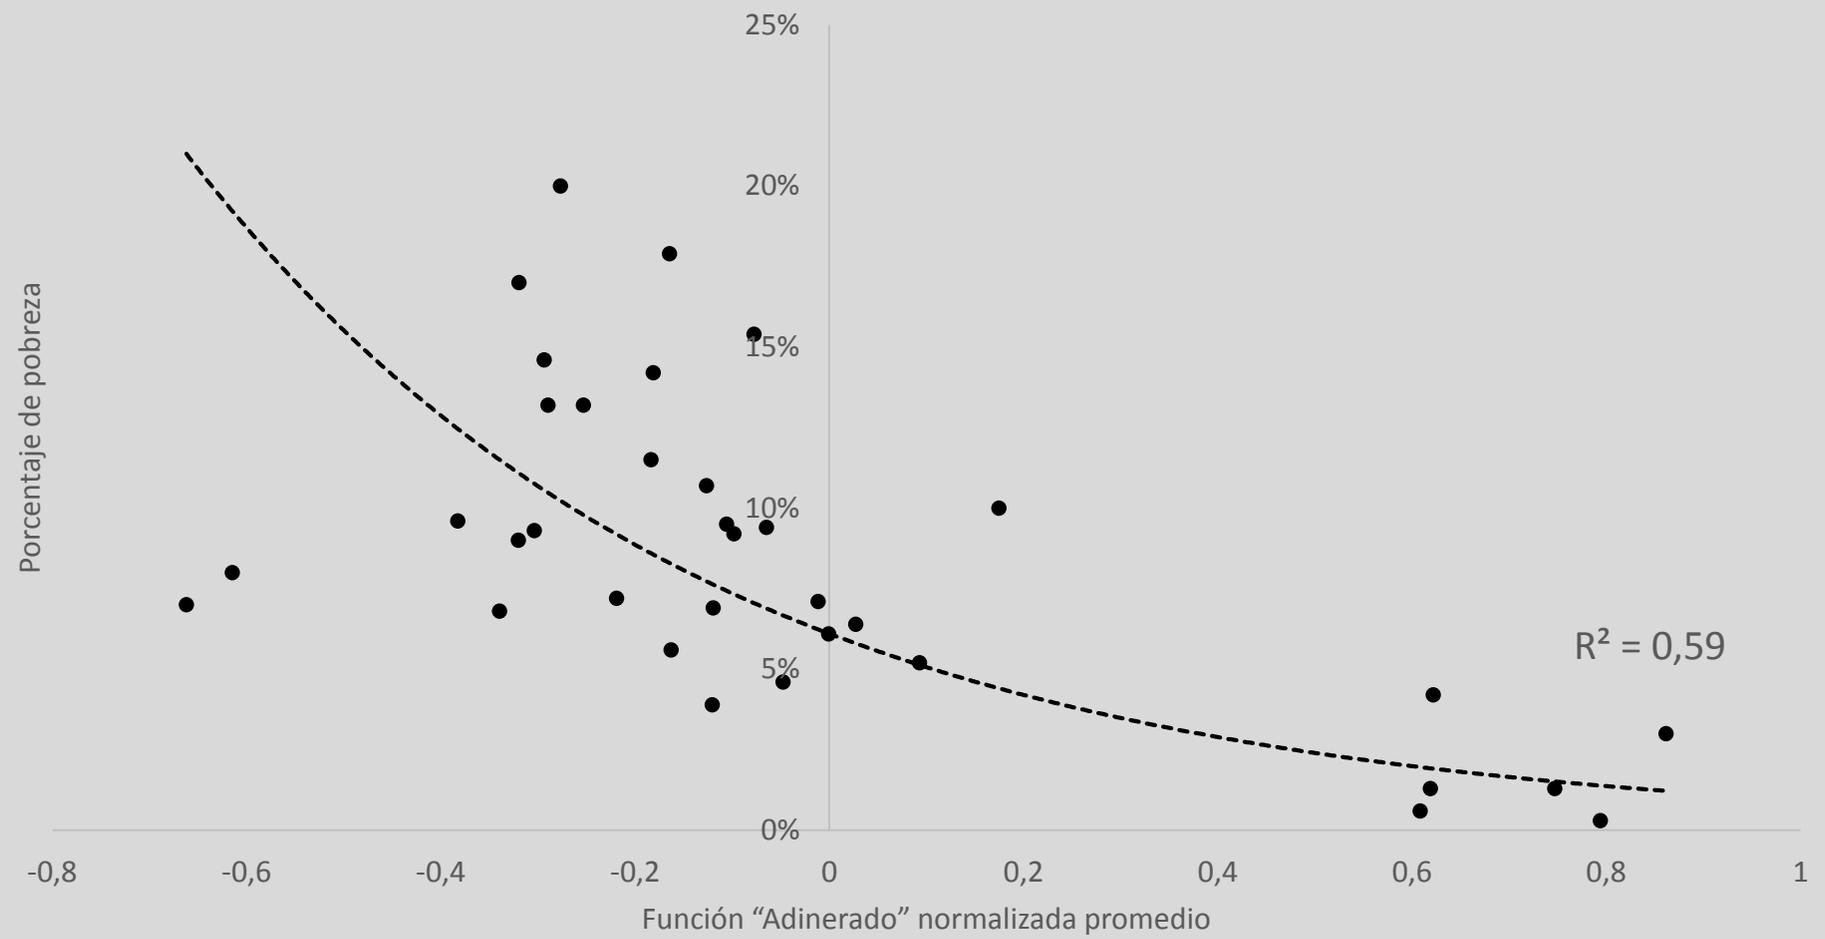




Adinerado

Validación: Alta correlación con indicadores de ingreso

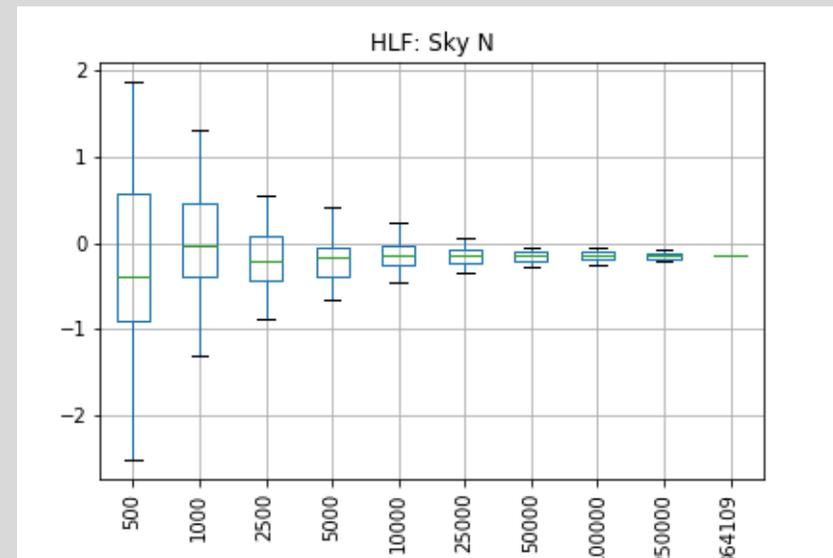
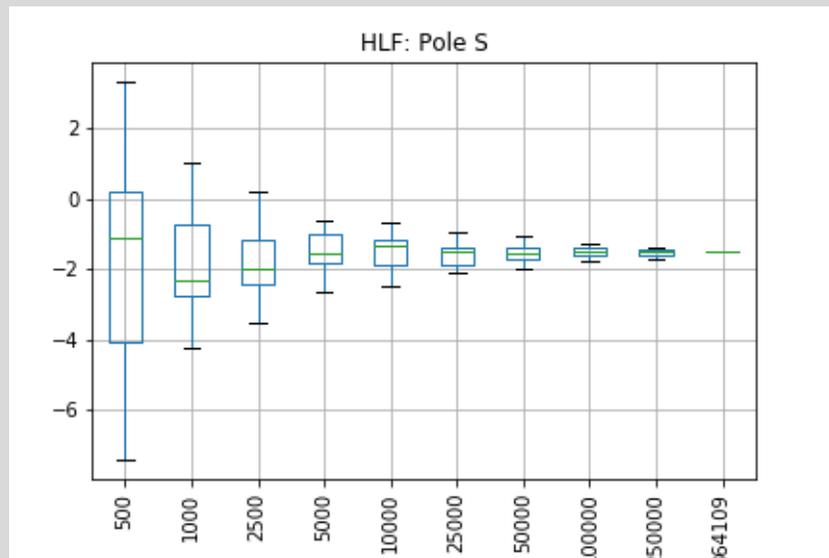
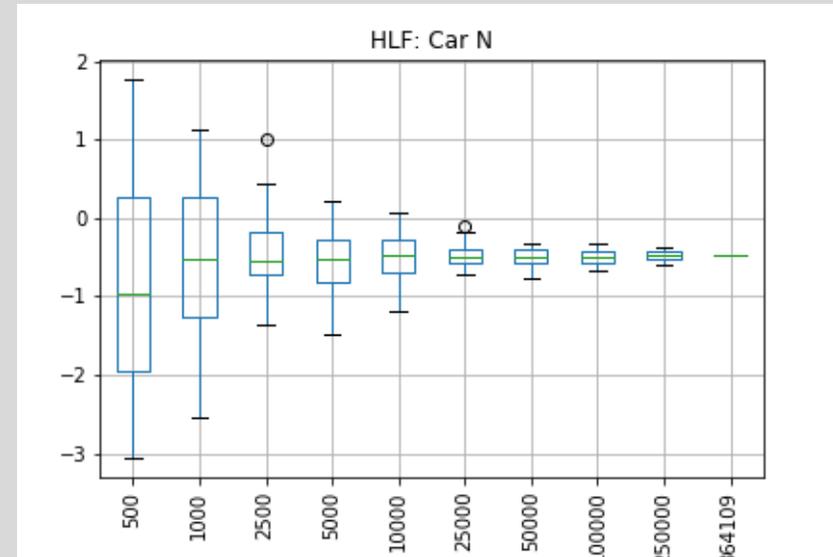
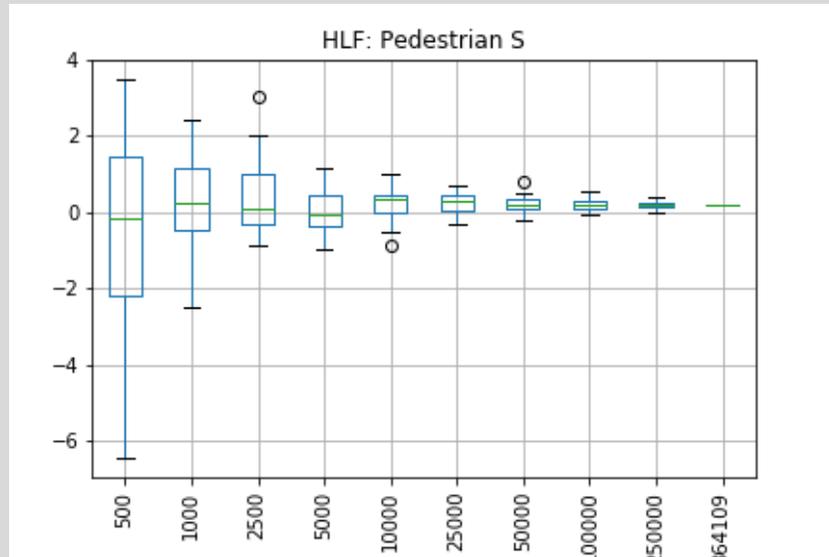
Utilidad “Adinerado” vs Porcentaje de pobreza por comuna (CASEN, 2013)



Conclusiones

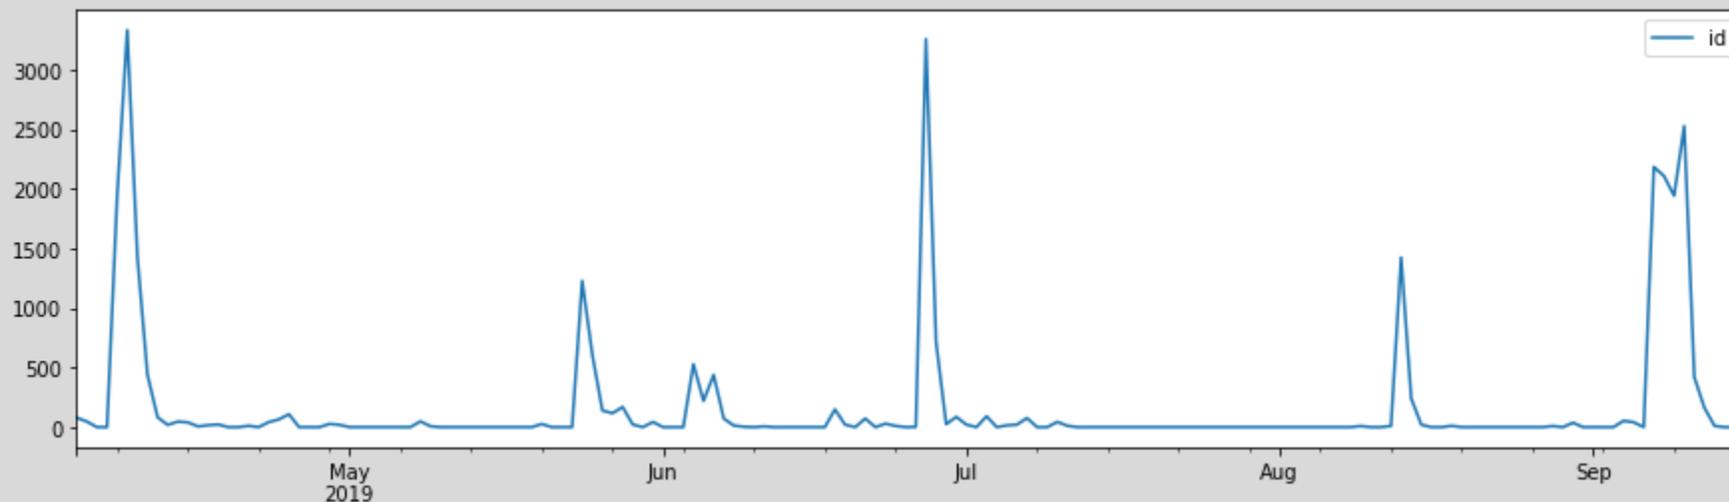
- 1) Las nuevas variables incorporadas (heterogeneidad, conteo de objetos) son relevantes en la modelación y permiten avanzar hacia modelos interpretables.
- 2) Estamos modelando decisiones muy complejas y al no tener un diseño experimental, hay mucho ruido que es necesario tener en cuenta antes de enunciar conclusiones generalizables.
- 3) Entrenar un segmentado semántico y detector de objetos en base al tipo de imágenes que estamos utilizando ayudaría a reducir ese ruido.
- 4) **Esperamos que un mayor tamaño muestral facilite el proceso de modelamiento.**
- 5) En la medida que la IA avance seremos capaces de detectar más variables que describan la imagen que complementen estos modelos.

Efecto de un mayor tamaño muestral



Hitos de la recolección de información

CANTIDAD DE OBSERVACIONES POR DÍA



TWITTER +
INSTAGRAM



REDDIT



TWITTER



INTERVENCIÓN
FÍSICA



TWITTER +
INSTAGRAM

Conclusiones

- 1) Las nuevas variables incorporadas (heterogeneidad, conteo de objetos) son relevantes en la modelación y permiten avanzar hacia modelos interpretables.
- 2) Estamos modelando decisiones muy complejas y al no tener un diseño experimental, hay mucho ruido que es necesario tener en cuenta antes de enunciar conclusiones generalizables.
- 3) Entrenar un segmentado semántico y detector de objetos en base al tipo de imágenes que estamos utilizando ayudaría a reducir ese ruido.
- 4) Esperamos que un mayor tamaño muestral facilite el proceso de modelamiento.
- 5) **En la medida que la IA avance seremos capaces de detectar más variables que describan la imagen que complementen estos modelos.**



Análisis de espacios públicos con modelos de inteligencia artificial y modelos de elección discreta

Tomás Ramírez

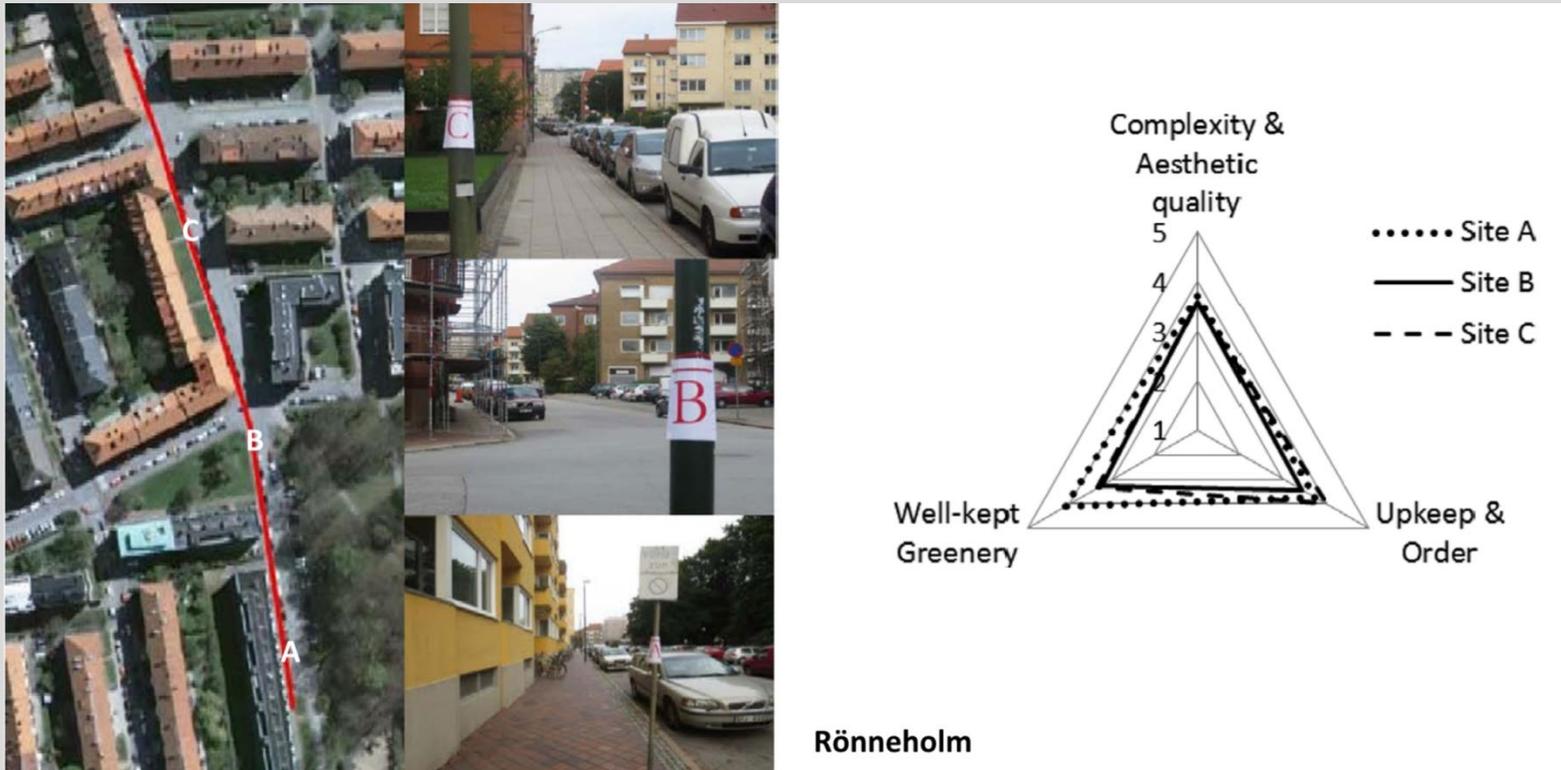
Tomás Rossetti - Hans Lobel - Ricardo Hurtubia

Departamento de Ingeniería de Transporte y Logística
Departamento de Ciencia de la Computación
Centro de Desarrollo Urbano Sustentable
Instituto Milenio Fundamento de los Datos

Pontificia Universidad Católica de Chile

1) Metodologías cualitativas

Encuestas y entrevistas presenciales



3) Aprendizaje automático



3) Aprendizaje automático

SEGURIDAD



ADINERADO



ÚNICO



* $0 \leq Q \leq 10$