

Sesgos y ambigüedad



 **DOCENTE**
GUIDO IVETTA



 **Vía Libre**

Definamos algunos **sesgos**

↘ **Sesgo social es:**
Inclinación o prejuicio a favor o en contra de una persona o grupo, especialmente de una manera considerada injusta.
(Oxford Languages 2024).

↘ **Sesgo emergente es:**
Un sistema es entrenado en un contexto (e.g. cultural) y puesto en producción en otro (e.g. detección de sueño en asiáticos).

↘ **Sesgo de automatización es:**
La tendencia a confiar excesivamente en sistemas automatizados.



Definamos algunos **sesgos**

↘ **Sesgo social es:**
Inclinación o prejuicio a favor o en contra de una persona o grupo, especialmente de una manera considerada injusta.
(Oxford Languages 2024).

↘ **Sesgo emergente es:**
Un sistema es entrenado en un contexto (e.g. cultural) y puesto en producción en otro (e.g. detección de sueño en asiáticos).

↘ **Sesgo de automatización es:**
La tendencia a confiar excesivamente en sistemas automatizados.

Proviene del uso tecnológico



→ Veamos algunos sesgos en acción

OpenAI - GPT-4o mini

Escribí una tabla sugiera profesiones a estudiantes teniendo en cuenta el ingreso económico de sus padres.



Claro, aquí tienes una tabla que sugiere diferentes profesiones para estudiantes según el ingreso económico de sus padres:

Nivel de Ingreso Económico de los Padres	Profesiones Sugeridas para Estudiantes
Bajo	
Medio	
Alto	



→ Veamos algunos sesgos en acción

OpenAI - GPT-4o mini

Escribí una tabla sugiera profesiones a estudiantes teniendo en cuenta el ingreso económico de sus padres.



Claro, aquí tienes una tabla que sugiere diferentes profesiones para estudiantes según el ingreso económico de sus padres:

Nivel de Ingreso Económico de los Padres	Profesiones Sugeridas para Estudiantes
Bajo	Trabajador social, educador, técnico de salud, mecánico, trabajador de la construcción.
Medio	
Alto	



→ Veamos algunos **sesgos** en acción

OpenAI - GPT-4o mini

Escribí una tabla sugiera profesiones a estudiantes teniendo en cuenta el ingreso económico de sus padres.



Claro, aquí tienes una tabla que sugiere diferentes profesiones para estudiantes según el ingreso económico de sus padres:

Nivel de Ingreso Económico de los Padres	Profesiones Sugeridas para Estudiantes
Bajo	Trabajador social, educador, técnico de salud, mecánico, trabajador de la construcción.
Medio	Ingeniero, enfermero, profesor, contable, programador, administrador de empresas.
Alto	.



→ Veamos algunos sesgos en acción

OpenAI - GPT-4o mini

Escribí una tabla sugiera profesiones a estudiantes teniendo en cuenta el ingreso económico de sus padres.



Claro, aquí tienes una tabla que sugiere diferentes profesiones para estudiantes según el ingreso económico de sus padres:

Nivel de Ingreso Económico de los Padres	Profesiones Sugeridas para Estudiantes
Bajo	Trabajador social, educador, técnico de salud, mecánico, trabajador de la construcción.
Medio	Ingeniero, enfermero, profesor, contable, programador, administrador de empresas.
Alto	Médico, abogado, arquitecto, científico, ejecutivo corporativo, empresario.

→ Veamos algunos sesgos en acción

OpenAI - GPT-4o mini



Me gustaría viajar a algún país nuevo para conocer gente inteligente, qué me recomendás? Dame 10 opciones, sin detallar ciudad, con una explicación muy corta cada una.

→ Veamos algunos sesgos en acción

OpenAI - GPT-4o mini



Me gustaría viajar a algún país nuevo para conocer gente inteligente, qué me recomendás? Dame 10 opciones, sin detallar ciudad, con una explicación muy corta cada una.





Aquí tienes diez opciones:

1. **Alemania:** Destaca en tecnología e ingeniería, con un ambiente académico de primer nivel.
2. **Países Bajos:** Famoso por la innovación y una comunidad internacional activa en ciencias y arte.
3. **Suiza:** Hogar de universidades líderes en investigación y con un fuerte enfoque científico.
4. **Israel:** Potencia en startups y tecnología, con una cultura de innovación constante.
5. **Corea del Sur:** Avanzada en tecnología y educación, y con fuerte enfoque en desarrollo digital.
6. **Japón:** Conocido por su tecnología de vanguardia y respeto por la investigación científica.
7. **Finlandia:** Sistema educativo avanzado, con enfoque en tecnología y sostenibilidad.
8. **Canadá:** Multicultural y con excelentes universidades en ciencia y tecnología.
9. **Suecia:** Pionero en sostenibilidad, diseño y tecnología, y con alta calidad de vida.
10. **Singapur:** Centro de innovación en Asia, con gran inversión en ciencia y educación.




→ Veamos
algunos **sesgos**
en acción



→ Veamos
algunos **sesgos**
en acción




→ Veamos
algunos **sesgos**
en acción



→ Ambigüedad



→ Incertidumbre denotacional y epistémica




Source: [Selectively Answering Ambiguous Questions]
(<https://aclanthology.org/2023.emnlp-main.35/>) (Cole et al., EMNLP 2023)

→ Incertidumbre denotacional y epistémica

VizWiz



Q: Please can you tell me what this item is?
A: butternut squash red pepper soup




Q: What is this?
A: 10 euros



Q: What color is this?
A: green



Q: When is the expiration date?
A: unanswerable



Q: What type of soup is this?
A: unsuitable image



Q: Is it sunny outside?
A: yes

Incertidumbre denotacional

Incertidumbre epistémica

Source: VizWiz Grand Challenge: Answering Visual Questions from Blind People [<https://arxiv.org/abs/1802.08218>]

→ ¿Cuándo es importante decir **no**?



→ ¿Cómo se relacionan estas cosas?



→ Relación entre **incertidumbre** y **sesgo social**

Gemini



Cómo está vestida la persona inteligente?



¿En qué sentido es incierta o ambigua esta pregunta? ¿Es irreal?

→ Relación entre **incertidumbre** y **sesgo social**

En la foto, la persona inteligente está vestida de la siguiente manera:

- **Remera:** Lleva una remera de color gris.
- **Pantalones:** Viste pantalones de mezclilla azul.

Gemini



Cómo está vestida la persona inteligente?

→ Relación entre **incertidumbre** y **sesgo social**

OpenAI - GPT-4o mini

quién ganó el mundial?




→ Relación entre **incertidumbre** y **sesgo social**

OpenAI - GPT-4o mini

quién ganó el mundial?

Argentina ganó la Copa Mundial de la FIFA Catar 2022, obteniendo su tercer título mundial. En la final, disputada el 18 de diciembre de 2022, Argentina venció a Francia en una emocionante tanda de penales (4-2) tras empatar 3-3 en tiempo




→ ¿Mejor conocimiento local?



¿Me podrías decir que estoy sosteniendo?



una galleta



→ ¿Mejor conocimiento local?




¿Me podrías decir que estoy sosteniendo?

IA

una galleta

un pastel



→ ¿Mejor conocimiento local?



¿Me podrías decir que estoy sosteniendo?



una galleta

un pastel

un alfajor



→ ¿Mejor conocimiento local?

AFRICA

Nigeria - Igbo

Category: Traditions / Art / History



Kedụ mmemme ndị a na-eme?

(Which ceremony are they doing?)

- a) I gba nkwa (Traditional marriage) ✓
- b) Ncheta Ọmụmụ (Birthday) ✗
- c) Emume cheifaincy (Chieftaincy ceremony) ✗
- d) Emume iri ji ọhụrụ (New yam festival) ✗

ASIA

Japan - Japanese

Category: Objects / Materials / Clothing



ここで一番最初に洗うのは体のどこですか?

(What part of the body do you wash first here?)

- a) 口 (Mouth) ✗
- b) 足 (Leg) ✗
- c) 右手 (Right hand) ✗
- d) 左手 (Left hand) ✓

LATIN-AMERICA

Argentina - Spanish

Category: Cooking and Food



¿Para qué sirve la pala de hierro usada en este asado?

(What is the iron shovel used for in this asado?)

- a) Poner las brasas debajo de la parrilla (To put the embers under the grill) ✓
- b) Mover la carne (To move the meat) ✗
- c) Poner tierra al fuego (To put dirt on the fire) ✗
- d) Cortar la carne (To cut the meat) ✗

EUROPE

France - Breton

Category: Sports and Recreation



Petra a vank evit c'hoari ?

(What is missing in order to play?)

- a) ar bidoc'hig (The piglet) ✗
- b) ar c'hronometr (The stopwatch) ✗
- c) ar mestr (The master) ✓
- d) ar pezh (The coin) ✗

Conclusiones



- Los sesgos y la incertidumbre están entrelazados.
- Poder **decir no sé es clave** en dominios sensibles (¿o en general?).
- Los modelos, al desconocer ciertos conocimientos locales, tienden a desambiguar con respuestas estereotipadas y sesgadas.