

Temas Selectos de Aprendizaje Automático

Objetivo: Comprender los diferentes paradigmas de aprendizaje y modelos en Machine Learning





MC. Gibrán Félix Zavala

gibran@spread.com

Maestría en Ciencias de la Computación en el CINVESTAV, mentor de IA en Saturdays.AI, una comunidad dedicada a aprender inteligencia artificial mediante la creación de proyectos con impacto social, tanto en la edición de Guadalajara como en la de América Latina. Cuenta con más de 10 años de experiencia implementando proyectos de Ciencia de Datos, Marketing Digital e Inteligencia de Negocios en empresas grandes y medianas de diversas industrias. En la actualidad, dirige su propia empresa desarrolladora de software, Spread, especializada en inteligencia artificial.



<https://www.linkedin.com/in/gibranfelix/>



<https://spread.com>

Agenda

01 Importancia y aplicaciones de la IA

02 Introducción y definiciones

03 Proceso de Machine Learning

04 Paradigmas de aprendizaje

05 Tipos de tareas resueltas por la ML

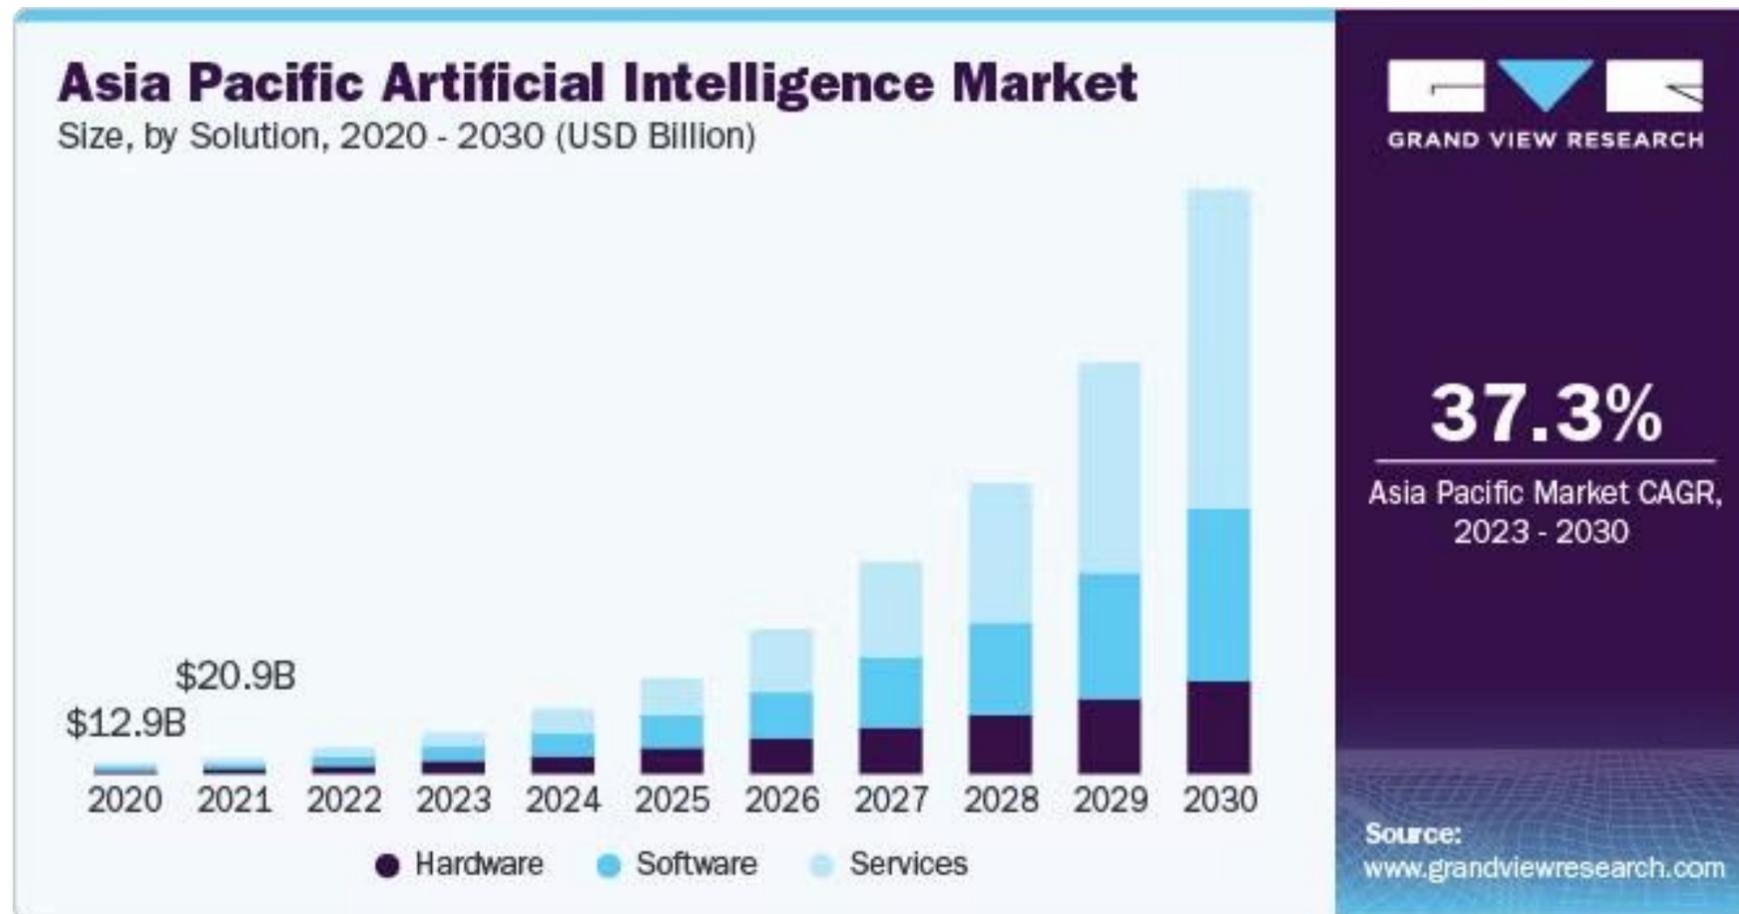
06 Code

07 Conclusiones

08 Dudas

Importancia y aplicaciones de la IA

Panorama actual de la IA



196.6

Billones de dólares de mercado en el 2023.

37%

Crecimiento anual del mercado.

1811.7

Billones de dólares de mercado en el 2030.

Importancia y aplicaciones de la IA

Aplicaciones

Datos

Desbloquea el potencial de los datos.

Optimización de Procesos:

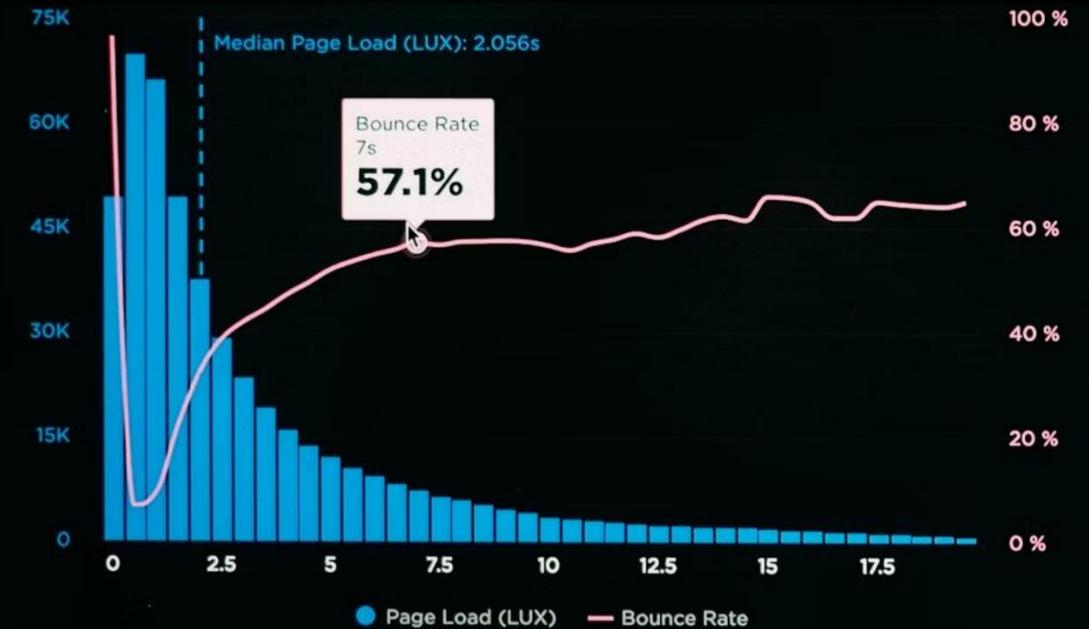
Toma de decisiones basado en datos y optimización operaciones.

Incrementa la competitividad

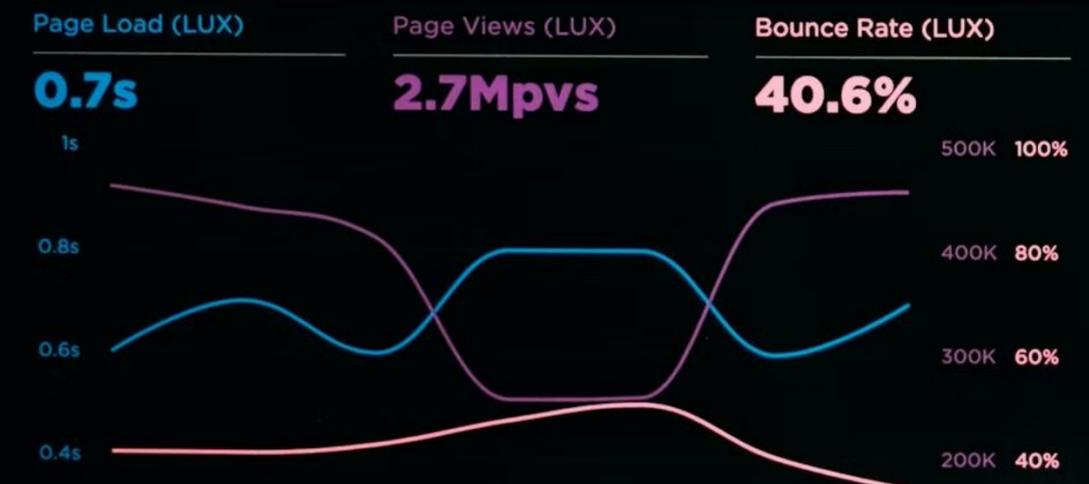
Personalización de la experiencia del cliente, mejora de la cadena de suministro.

USERS: LAST 7 DAYS USING MEDIAN ▾

LOAD TIME VS BOUNCE RATE



PAGE VIEWS VS ONLOAD



SESSIO

Session

479

4 pvs

3.2 pvs

2.4 pvs

1.6 pvs

Introducción

Definiciones

Inteligencia Artificial

Campo de estudio que otorga a las computadoras la capacidad de aprender sin ser programadas explícitamente.

Arthur Samuel (1959).



Introducción

Definiciones

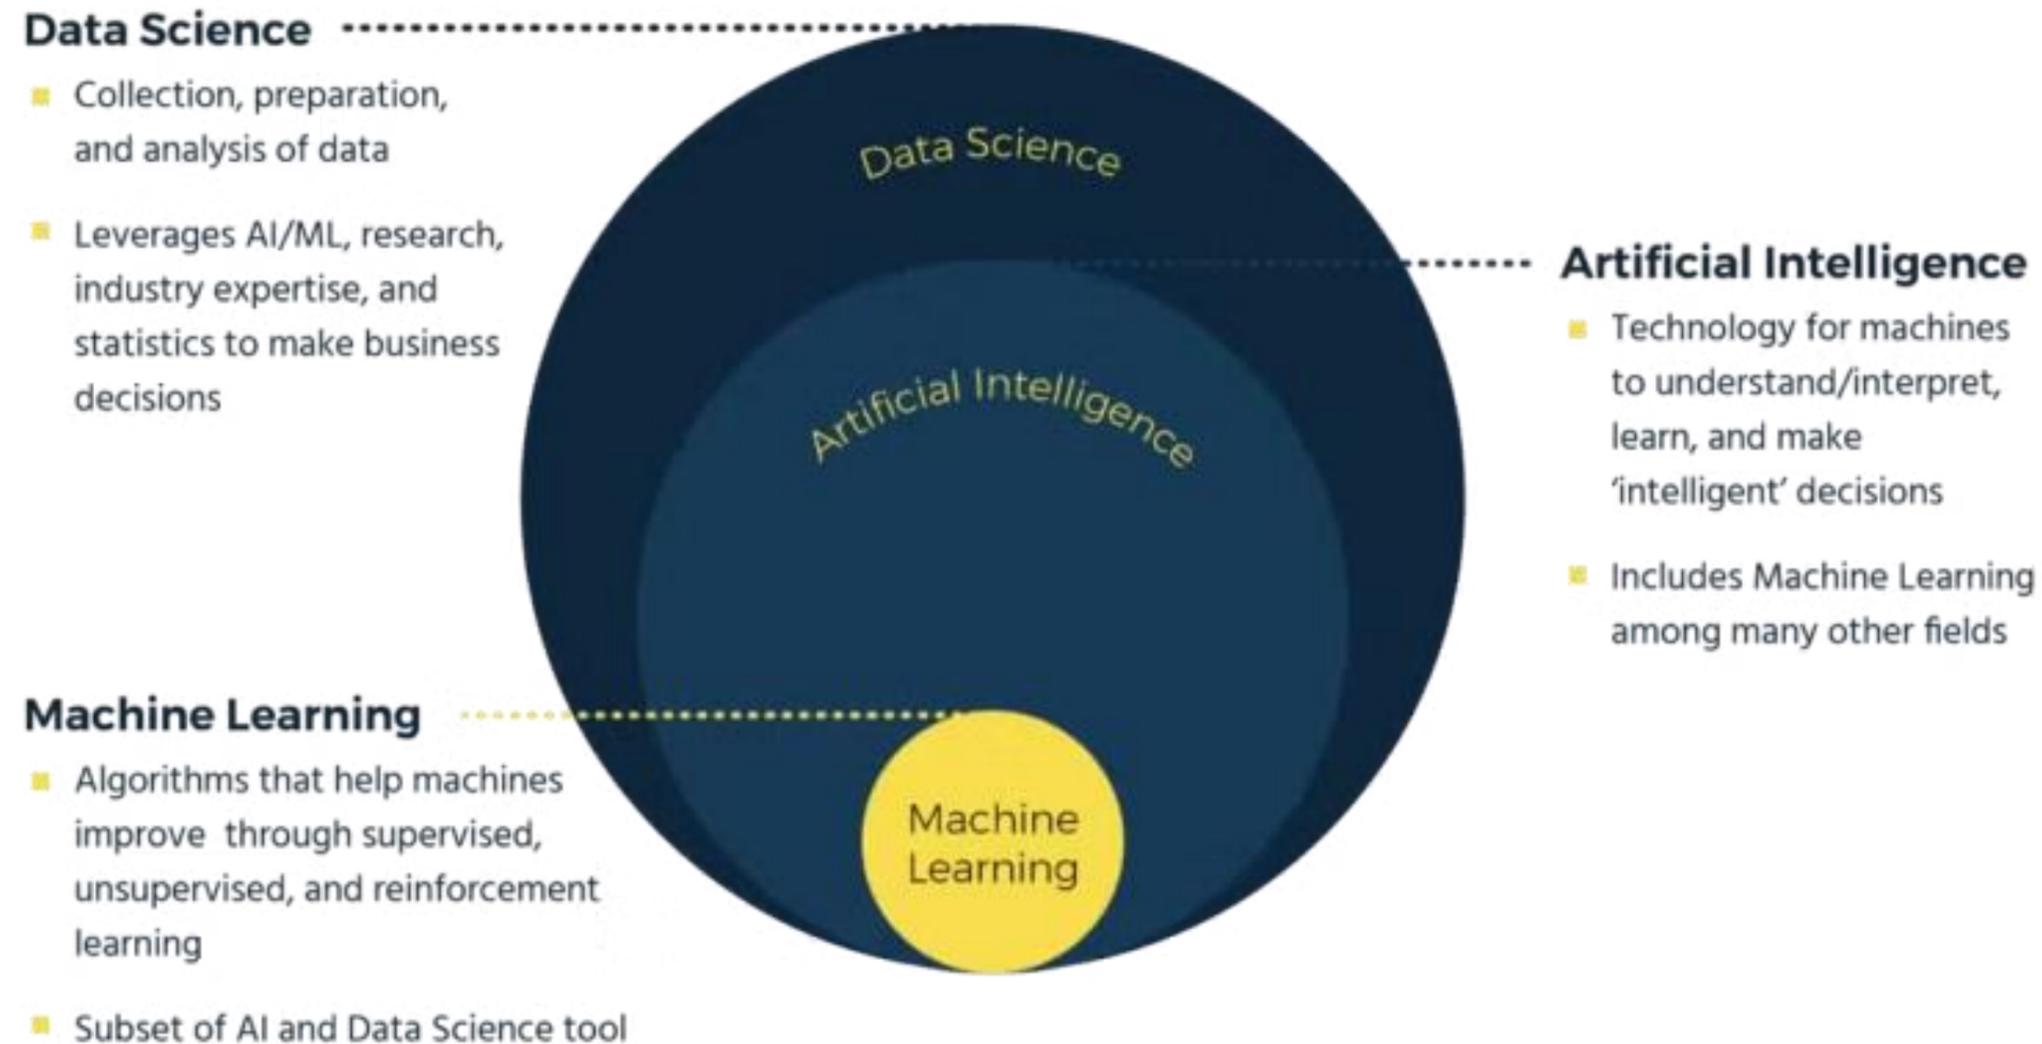
Machine Learning

Subconjunto de la inteligencia artificial (IA). Se enfoca en enseñar a las computadoras para que **aprendan** de los **datos** y **mejoren con la experiencia** en una **tarea específica**.



Introducción

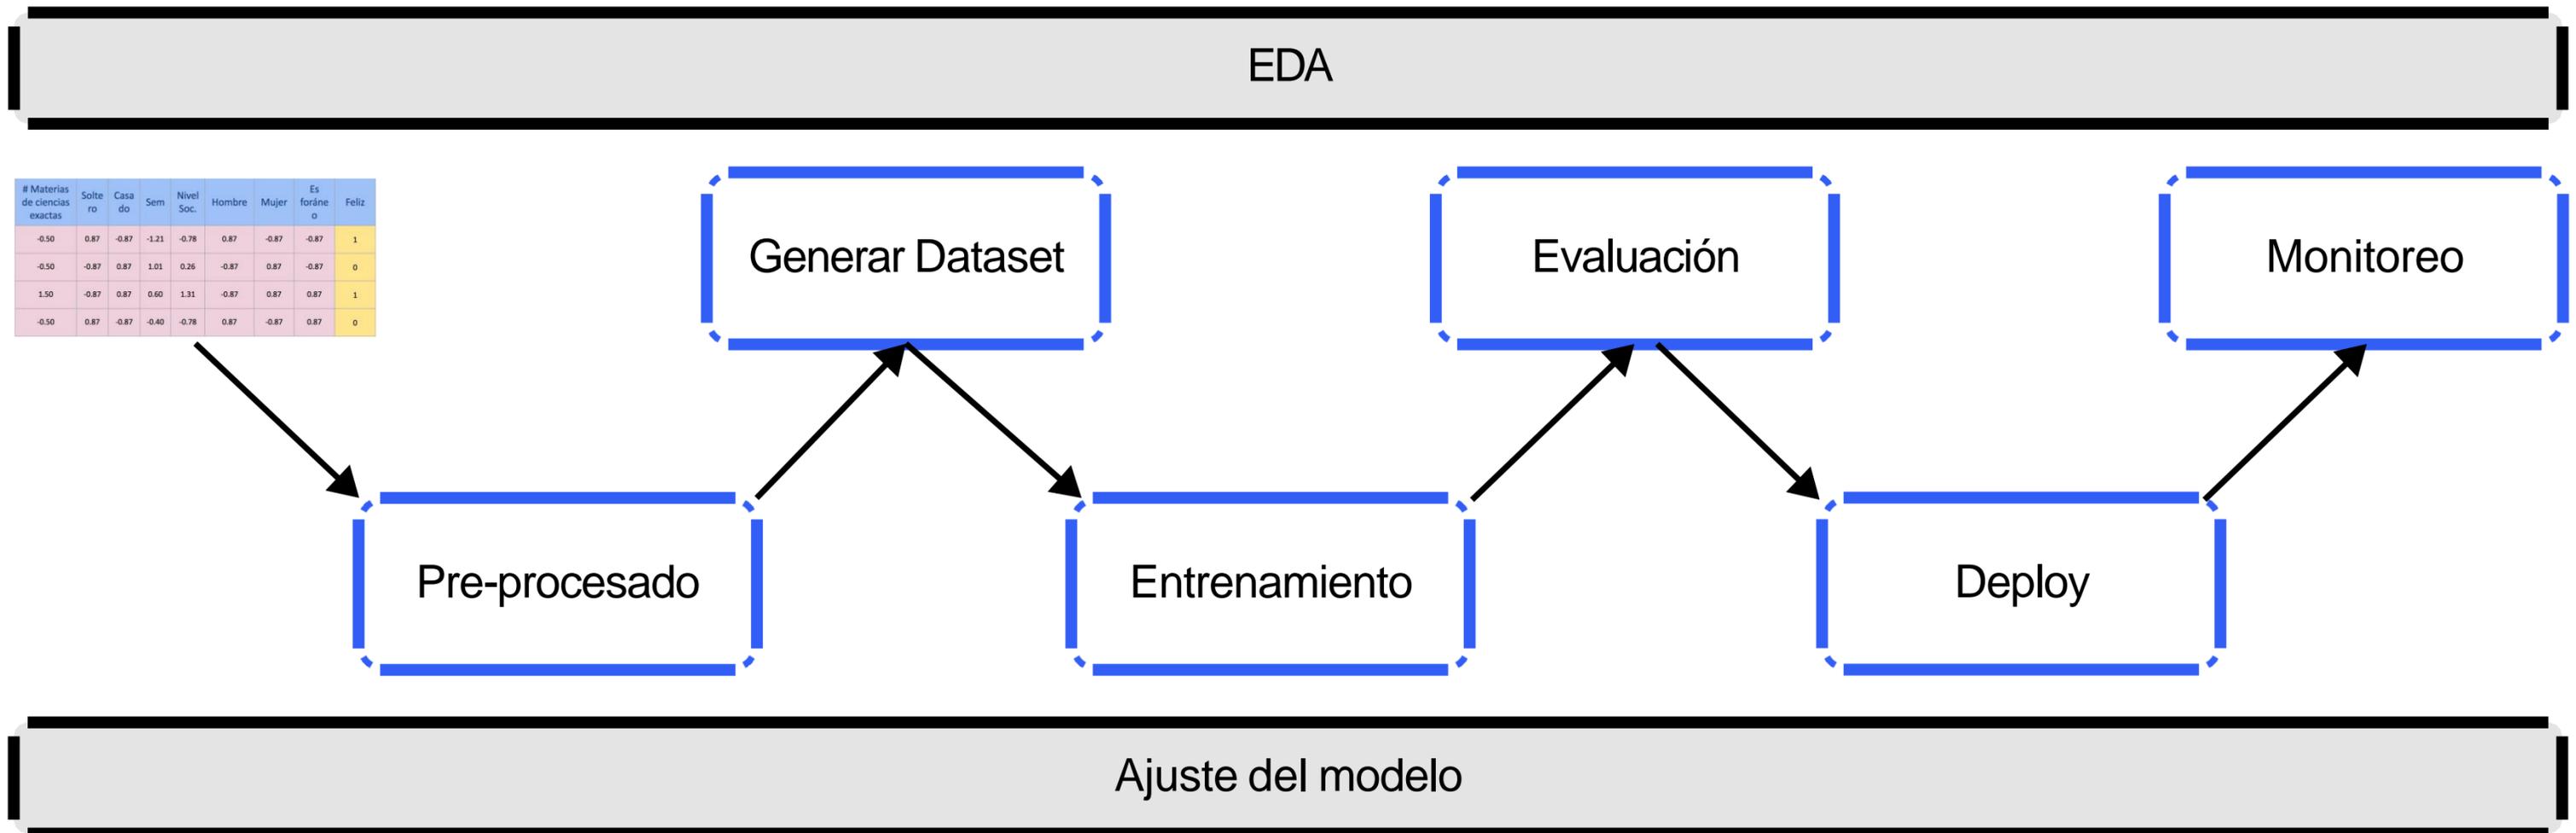
Machine Learning vs IA



Fuente: <https://braincube.com/resource/manufacturing-ai-vs-machine-learning-vs-data-science/>

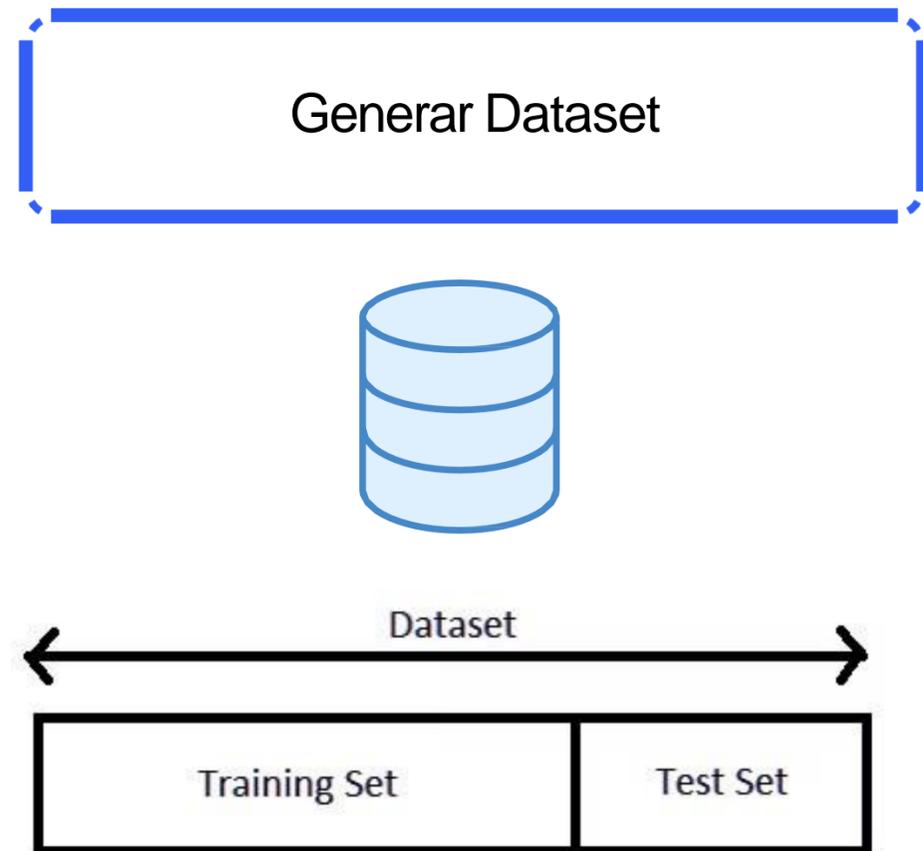
Proceso de Machine Learning

Proceso de Machine Learning



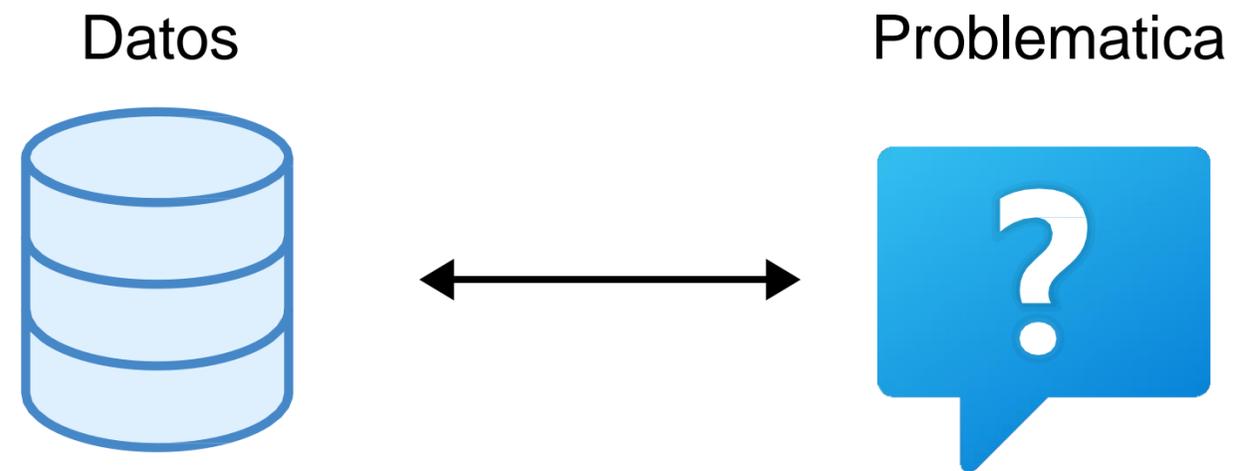
Proceso de Machine Learning

Generación de Dataset



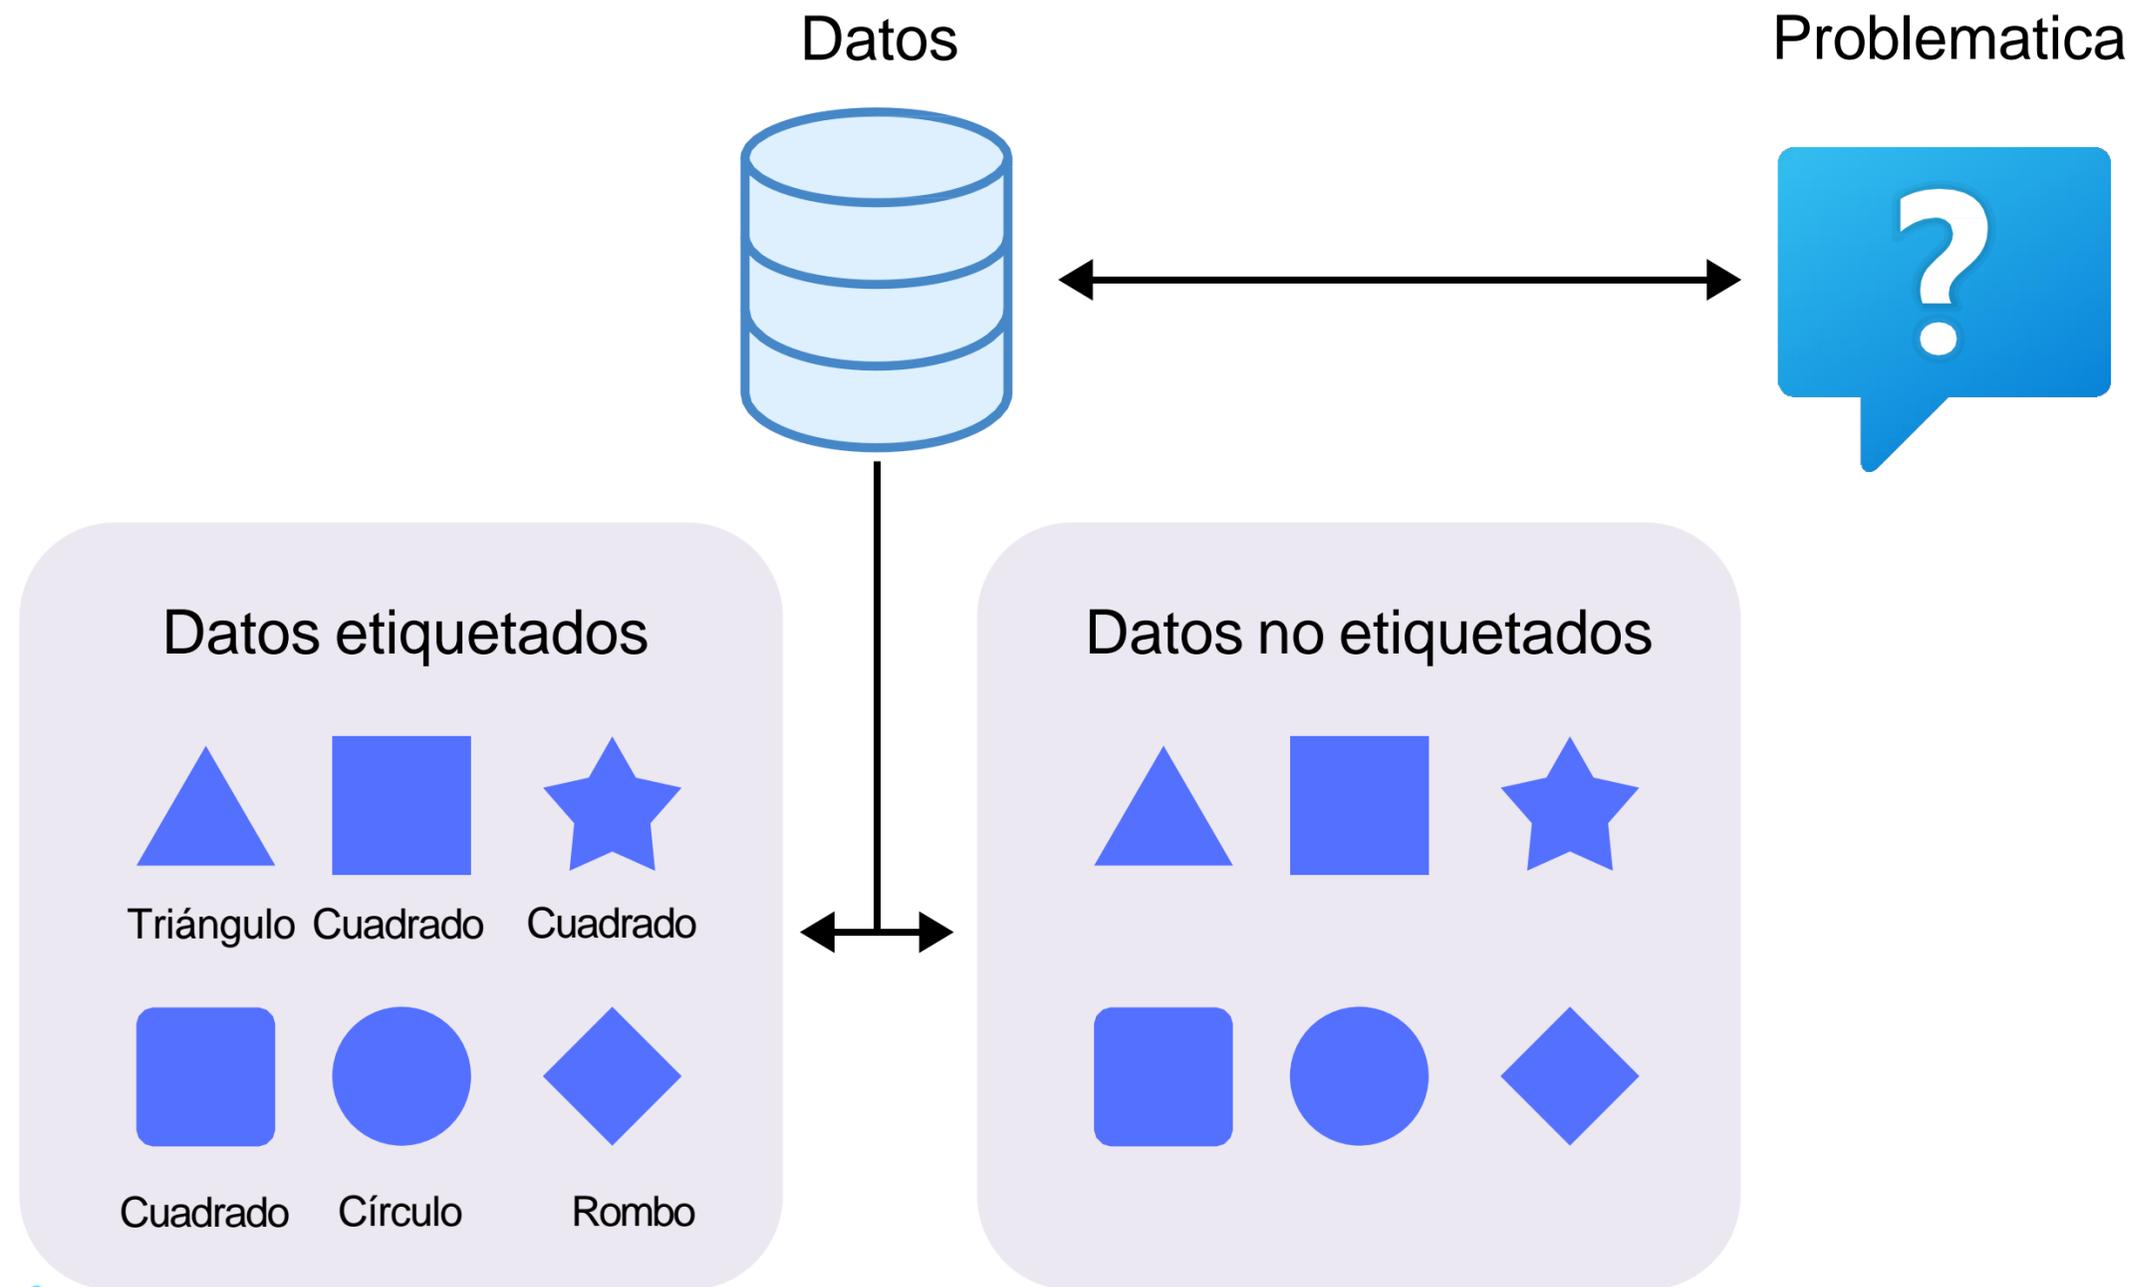
Proceso de Machine Learning

¿Como empezamos? **Datos + problema**



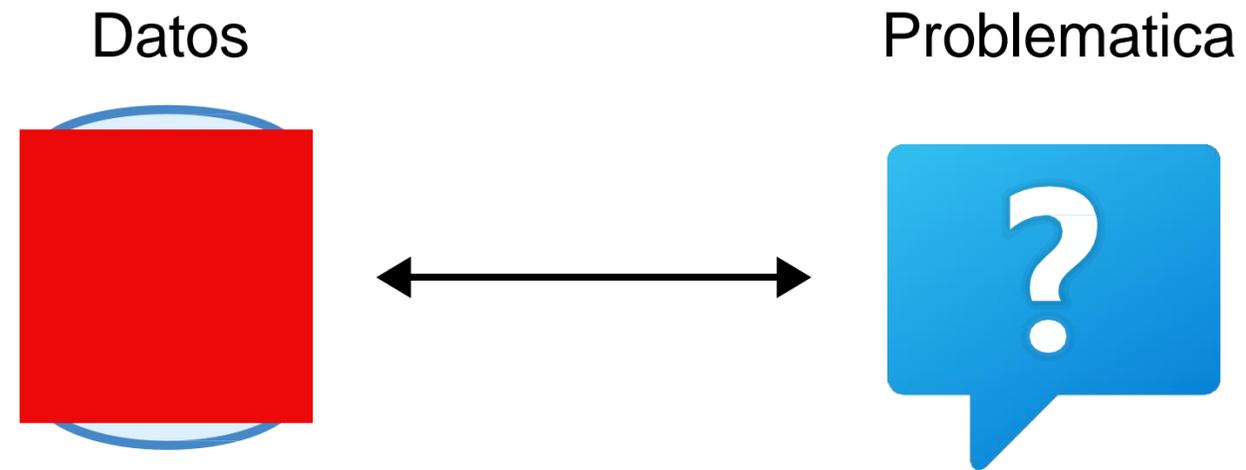
Proceso de Machine Learning

¿Como empezamos? **Datos + problema**



Proceso de Machine Learning

¿Como empezamos? Datos + problema



Paradigmas de aprendizaje en Machine Learning

Paradigmas de aprendizaje

Aprendizaje supervisado

- El aprendizaje supervisado utiliza un **conjunto de datos etiquetados** para **enseñar** a los **modelos** a producir el **resultado deseado**.
- El algoritmo evalúa su precisión utilizando una **función de pérdida**, realizando **ajustes hasta minimizar el error** a un nivel satisfactorio.
- **Caso de uso:** Cuando se tiene una gran cantidad de datos etiquetados.



Paradigmas de aprendizaje

Aprendizaje no supervisado

- Utiliza un conjunto de **datos sin etiquetas** para **descubrir patrones y estructuras** subyacentes en los datos.
- El modelo busca **identificar agrupaciones, relaciones o características** interesantes dentro de los datos.
- El algoritmo **evalúa** la calidad de los resultados **utilizando métricas** como la **cohesión de clústeres** o la reducción de dimensionalidad, **ajustando el modelo para mejorar la estructura revelada** en los datos.
- **Caso de uso:** Cuando se tiene una gran cantidad, pero no se tienen las etiquetas.



Paradigmas de aprendizaje

Aprendizaje semi supervisado

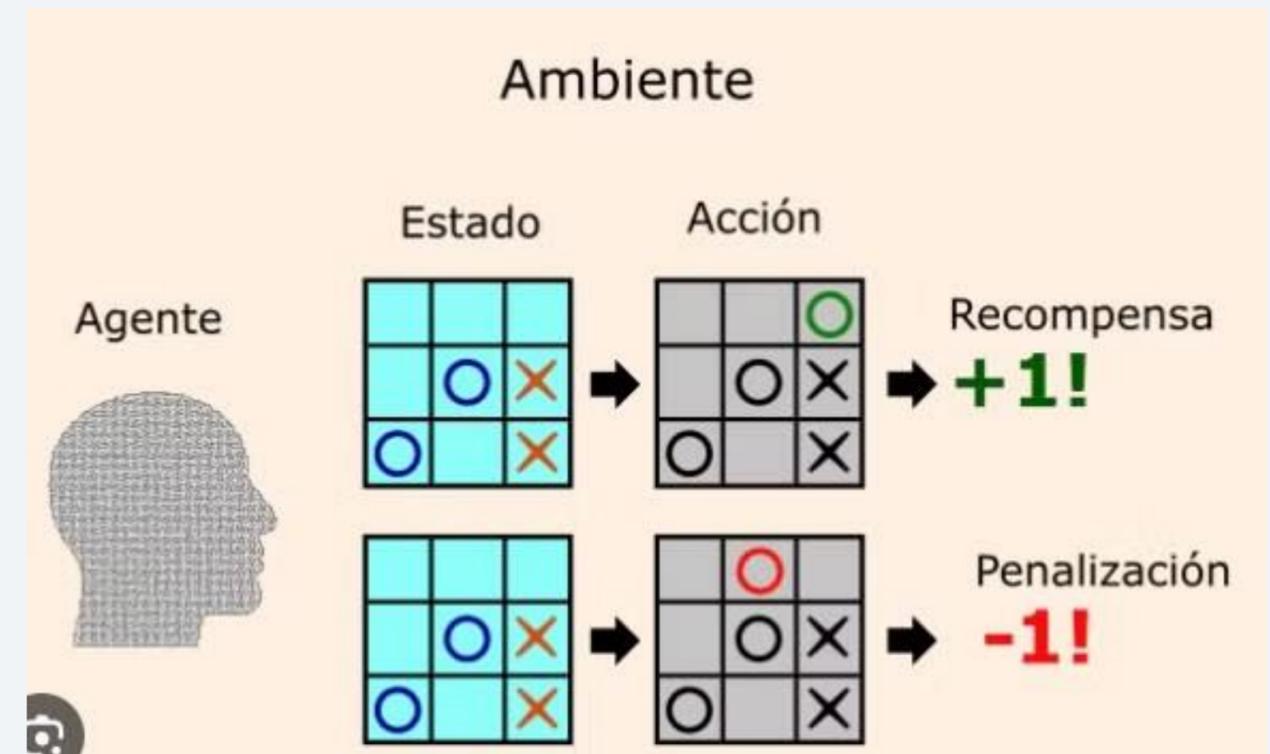
- **Combina** un conjunto de **datos etiquetados** con un conjunto de **datos no etiquetados** para mejorar el rendimiento del modelo.
- El modelo **utiliza** los **datos etiquetados** para aprender las **relaciones entre entradas y salidas**, mientras que los **datos no etiquetados** ayudan a identificar patrones adicionales y **mejorar la generalización**.
- **Caso de uso:** Comúnmente cuando se tiene una gran cantidad sin etiquetas y pocos datos etiquetados.



Paradigmas de aprendizaje

Aprendizaje por refuerzo

- Enseña a un modelo a **tomar decisiones** mediante la **interacción con un entorno** y la recepción de **recompensas o penalizaciones** en función de sus acciones.
- El modelo explora diferentes acciones para **maximizar la recompensa**, aprendiendo a optimizar su comportamiento a través de la **retroalimentación del entorno**.
- **Caso de uso:** Cuando el problema involucra una secuencia de decisiones en un entorno dinámico, y la retroalimentación se recibe después una o varias acciones.



Paradigmas de aprendizaje

Aplicaciones

Supervisado

- Detección de fraude.
- Reconocimiento de voz.
- Clasificación de imágenes.
- Filtrado de spam.
- Forecasting de inventario.

No Supervisado

- Segmentación de clientes.
- Análisis de patrones.
- Detección de anomalías.
- Agrupamiento de documentos.
- Sistemas de recomendación.
- Generación de imágenes.

Semi-Supervisado

- *Todas las de aprendizaje supervisado.*

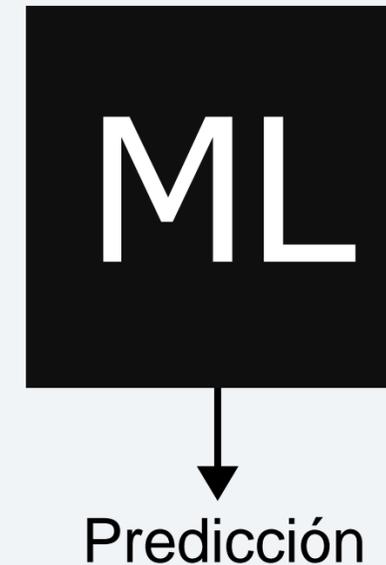
Por Refuerzo

- Control de robots.
- Juegos.
- Sistemas de recomendación
- Optimización de rutas.
- Optimización de Publicidad en Línea

Paradigmas de aprendizaje

Extra: Zero-shot learning (ZSL)

- El **Zero-Shot Learning (ZSL)** permite a los modelos reconocer y clasificar clases para las cuales **no tienen ejemplos de entrenamiento directos**.
- Zero-Shot Learning (ZSL) se puede **implementar utilizando modelos fundacionales**.
- Los modelos fundacionales tienen la **capacidad de entender y generar información** sobre una amplia gama de conceptos y tareas debido a su entrenamiento en **grandes volúmenes de datos**.
- **Caso de uso:** No se tiene datos y hay un modelo que resuelve el problema.

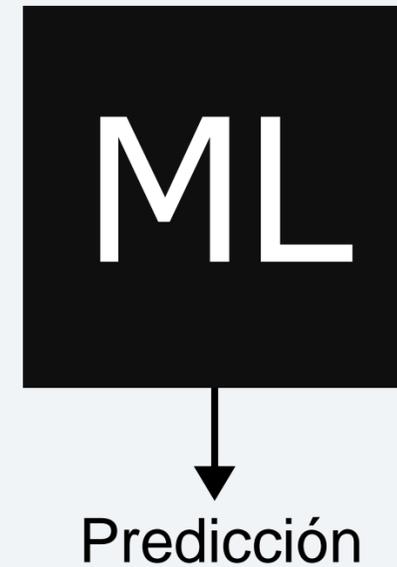


Paradigmas de aprendizaje

Extra: Modelos fundacionales

Modelos Fundacionales

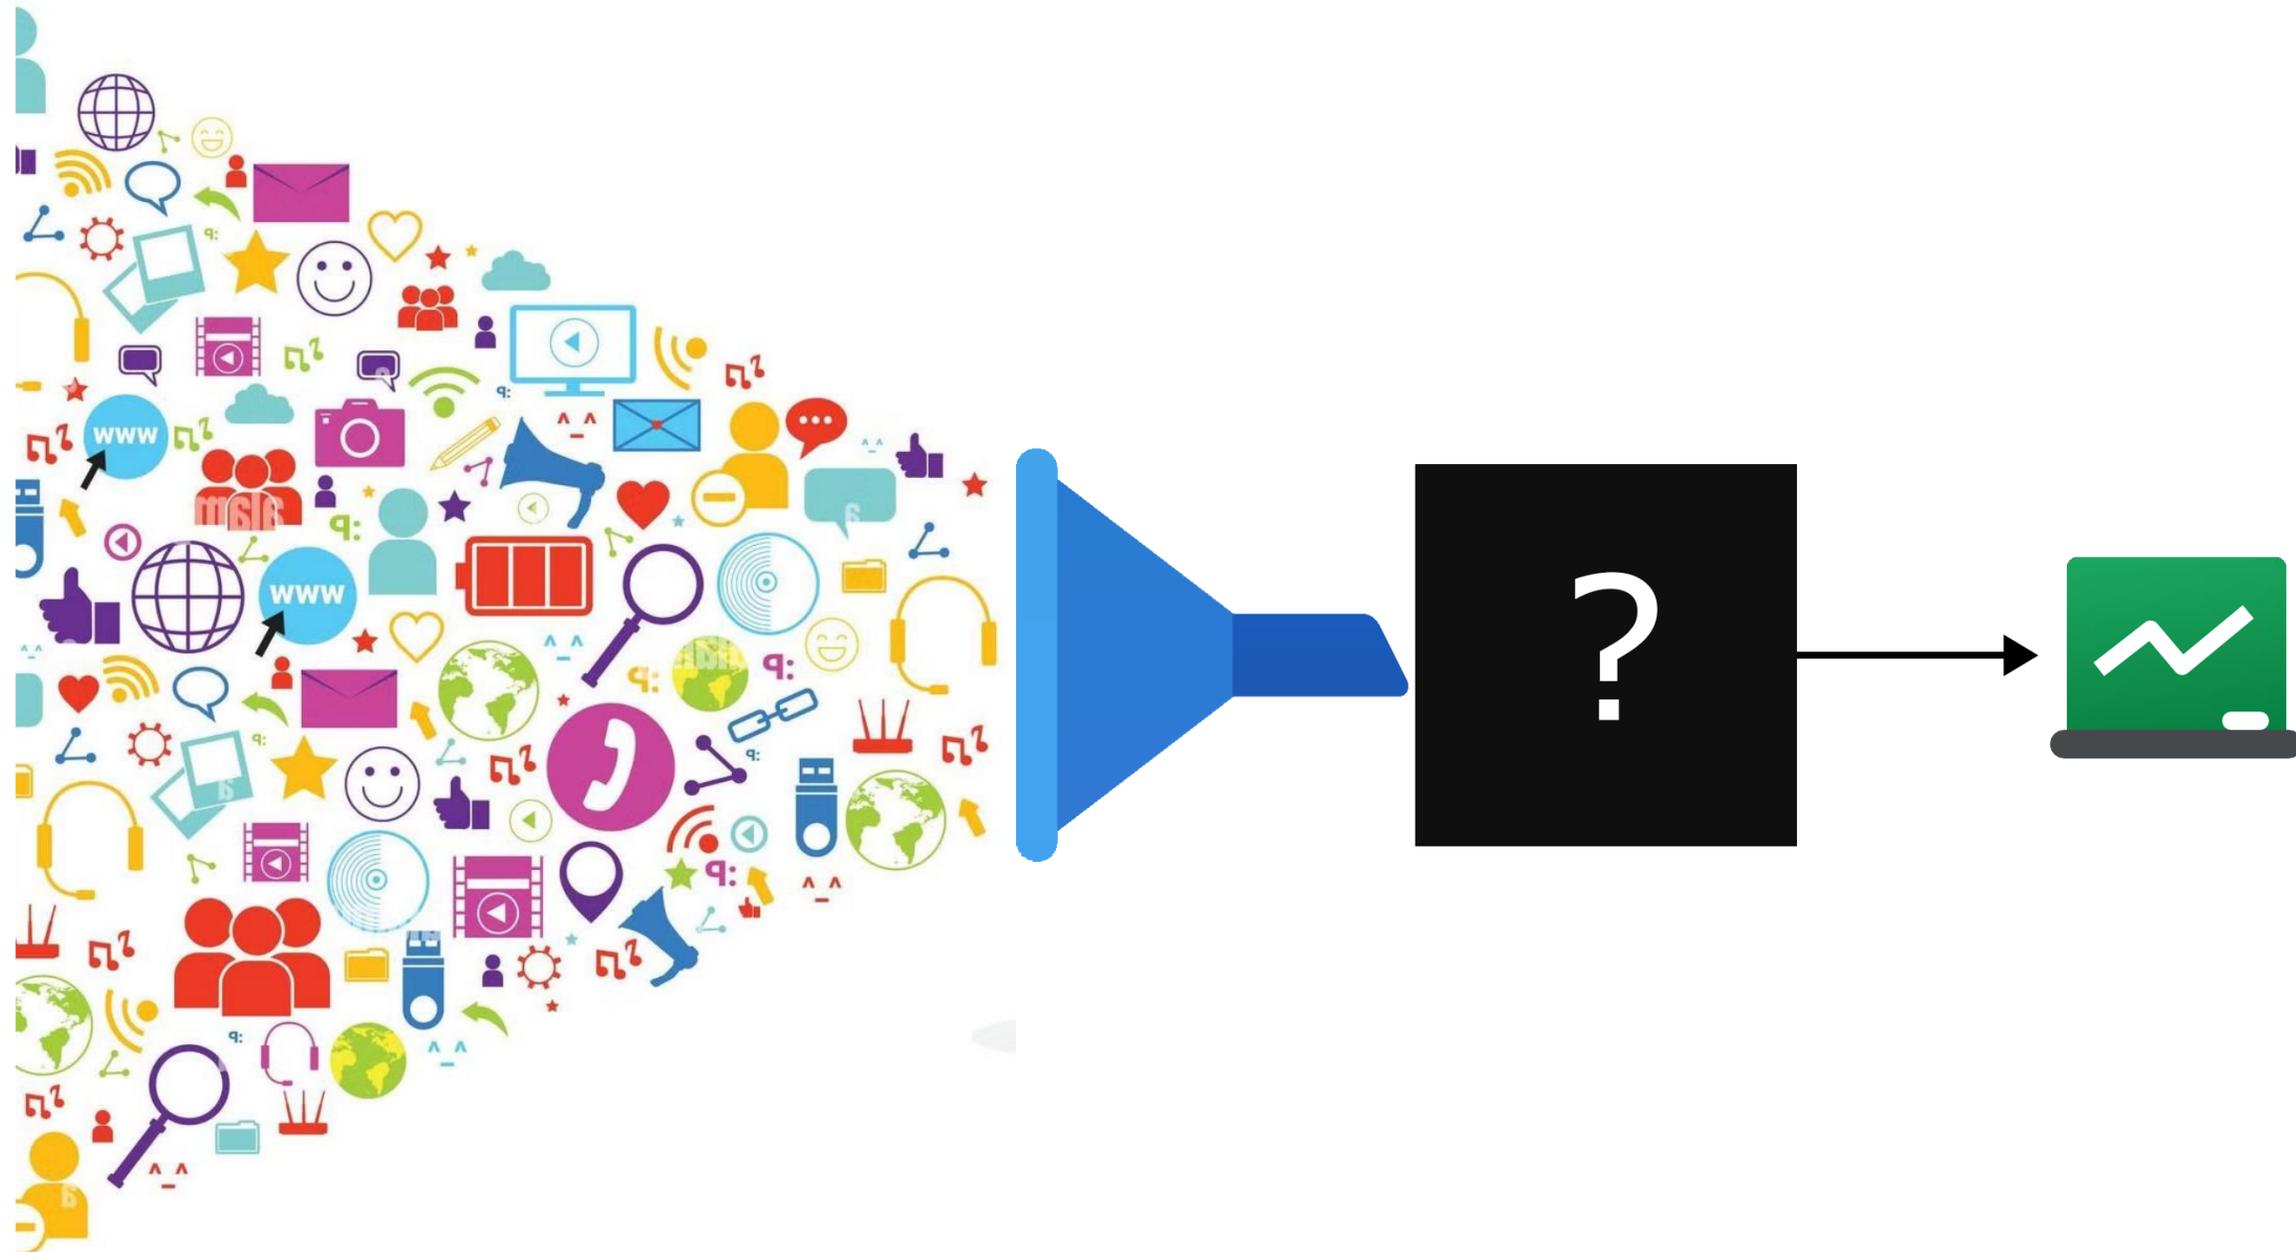
- LLMs.
- SAM (Segment Anything Model).
- DALL-E / MidJourney / MidJourney / FLUX.
- Whisper.
- CLIP (Contrastive Language-Image Pre-training).
- Sora / Pika.
- TimesFM (Time Series Foundation Model)



Tipos de tareas resueltas por Machine Learning

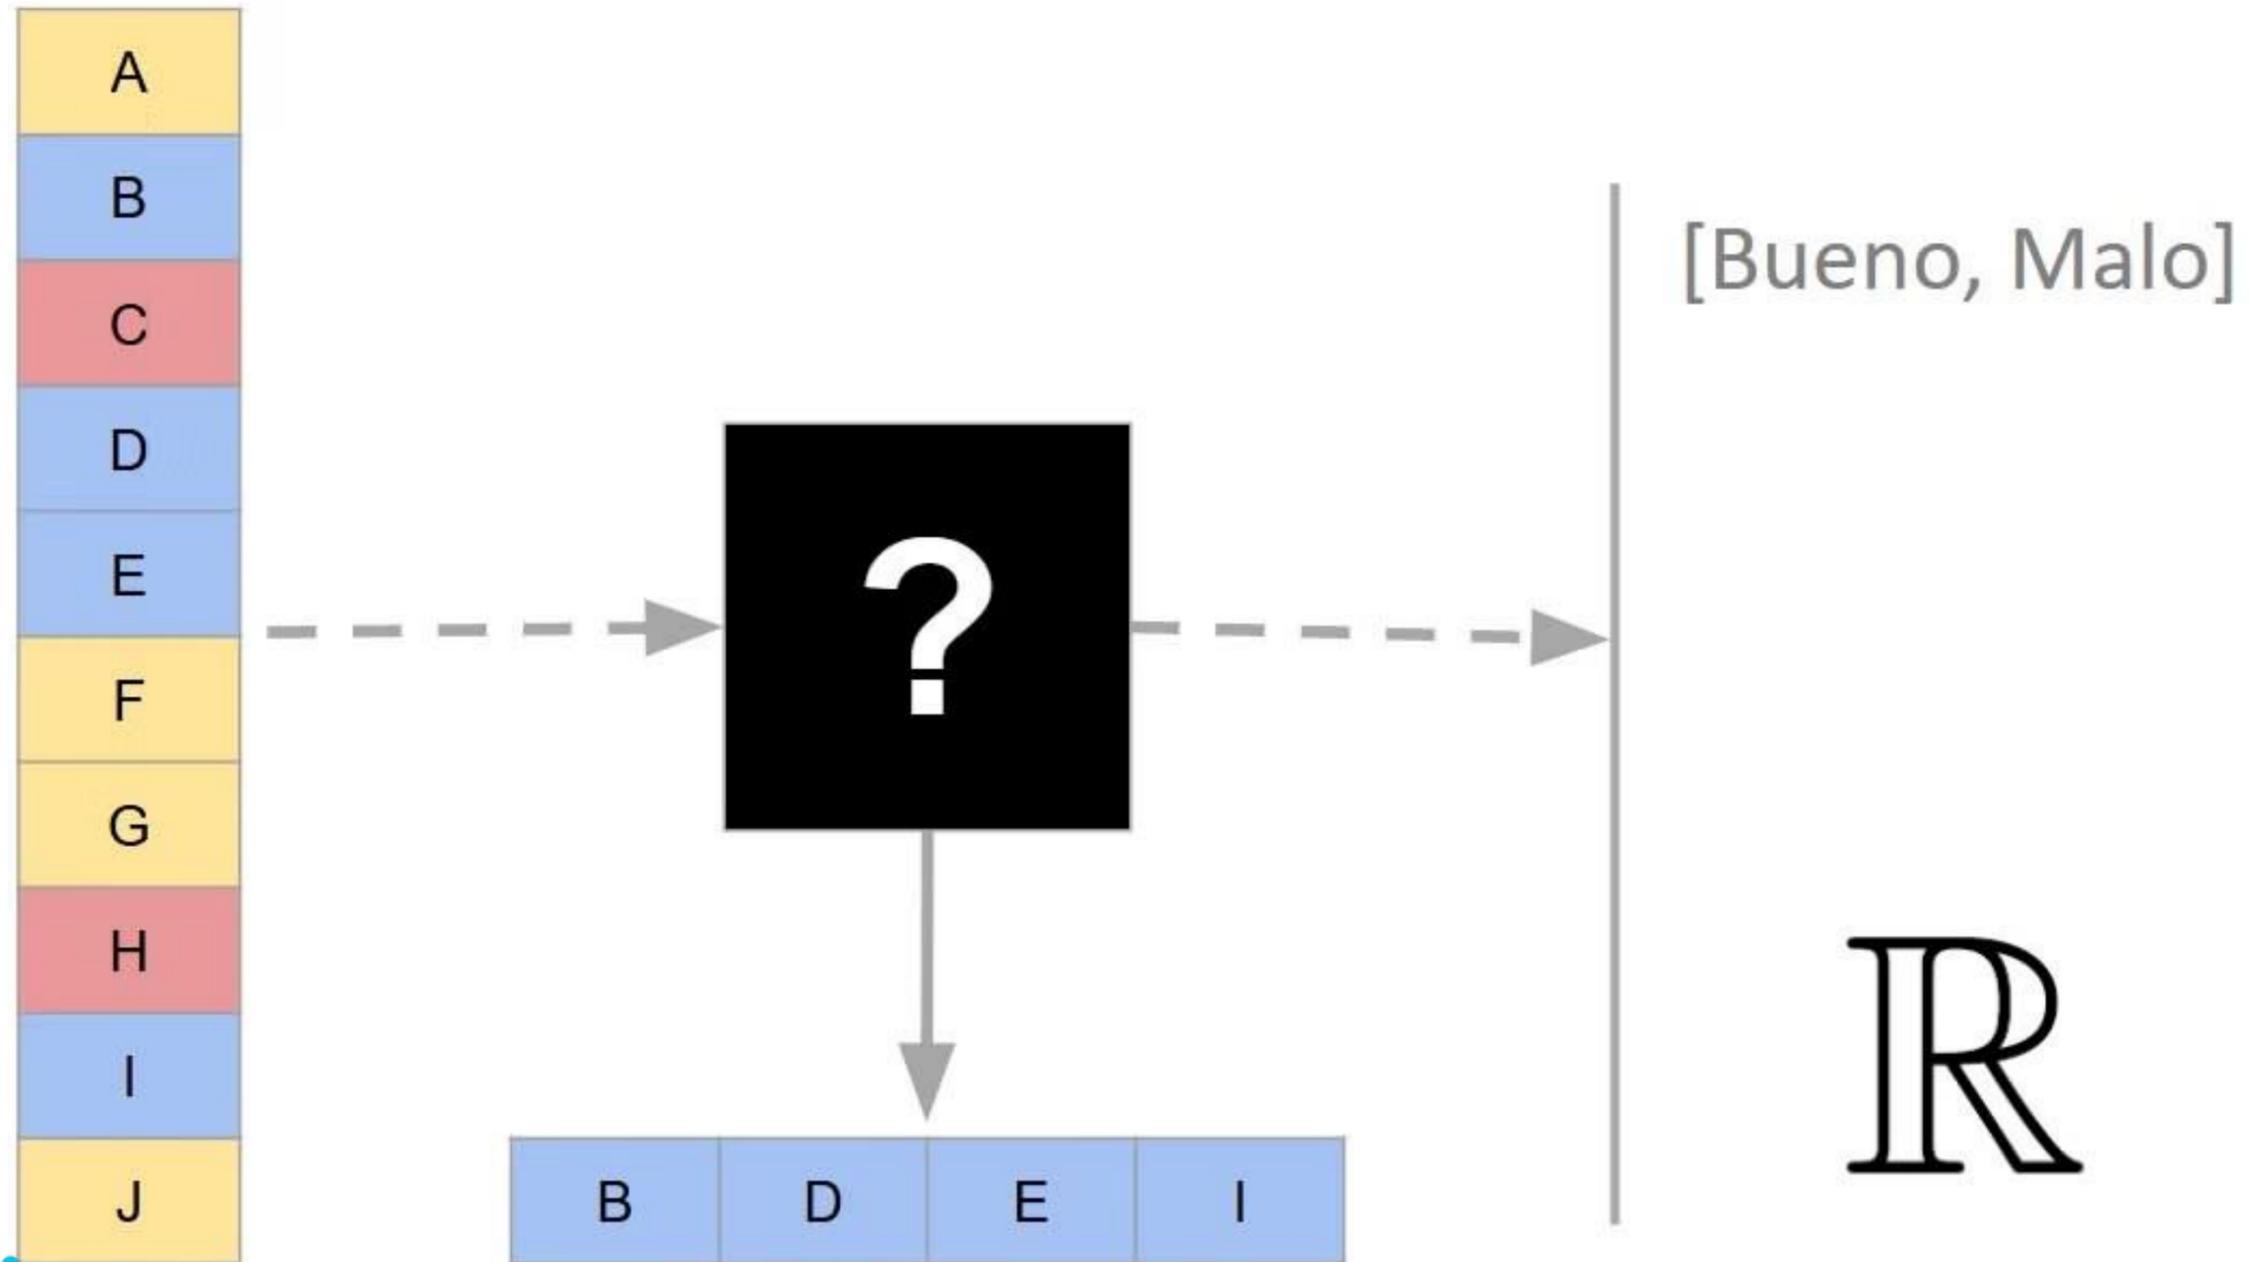
Tareas

Regresión



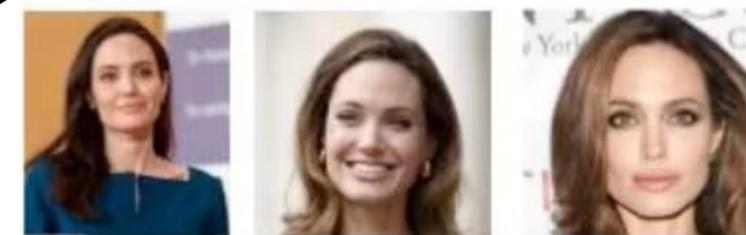
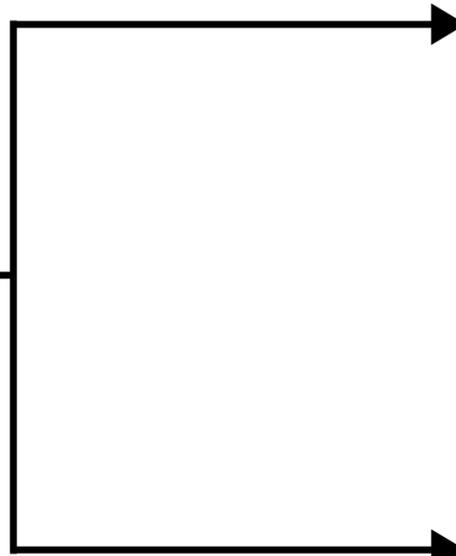
Tareas

Feature Importance



Tareas

Clustering



Paradigmas de aprendizaje

Modelos

Regresión

Tipo: Supervisado.

Modelos:

- Regresión Lineal.
- Random Forest Regressor.
- Support Vector Regression (SVR).
- XGBoost.
- Redes neuronales.

Clasificación

Tipo: Supervisado.

Modelos:

- Regresión Logística.
- Random Forest.
- Support Vector Machines (SVM).
- Redes Neuronales.

Feature Importance

Tipo: Supervisado / No Supervisado.

Modelos:

- Random Forest.
- Gradient Boosting Machines (GBM).
- SHAP.

Clustering

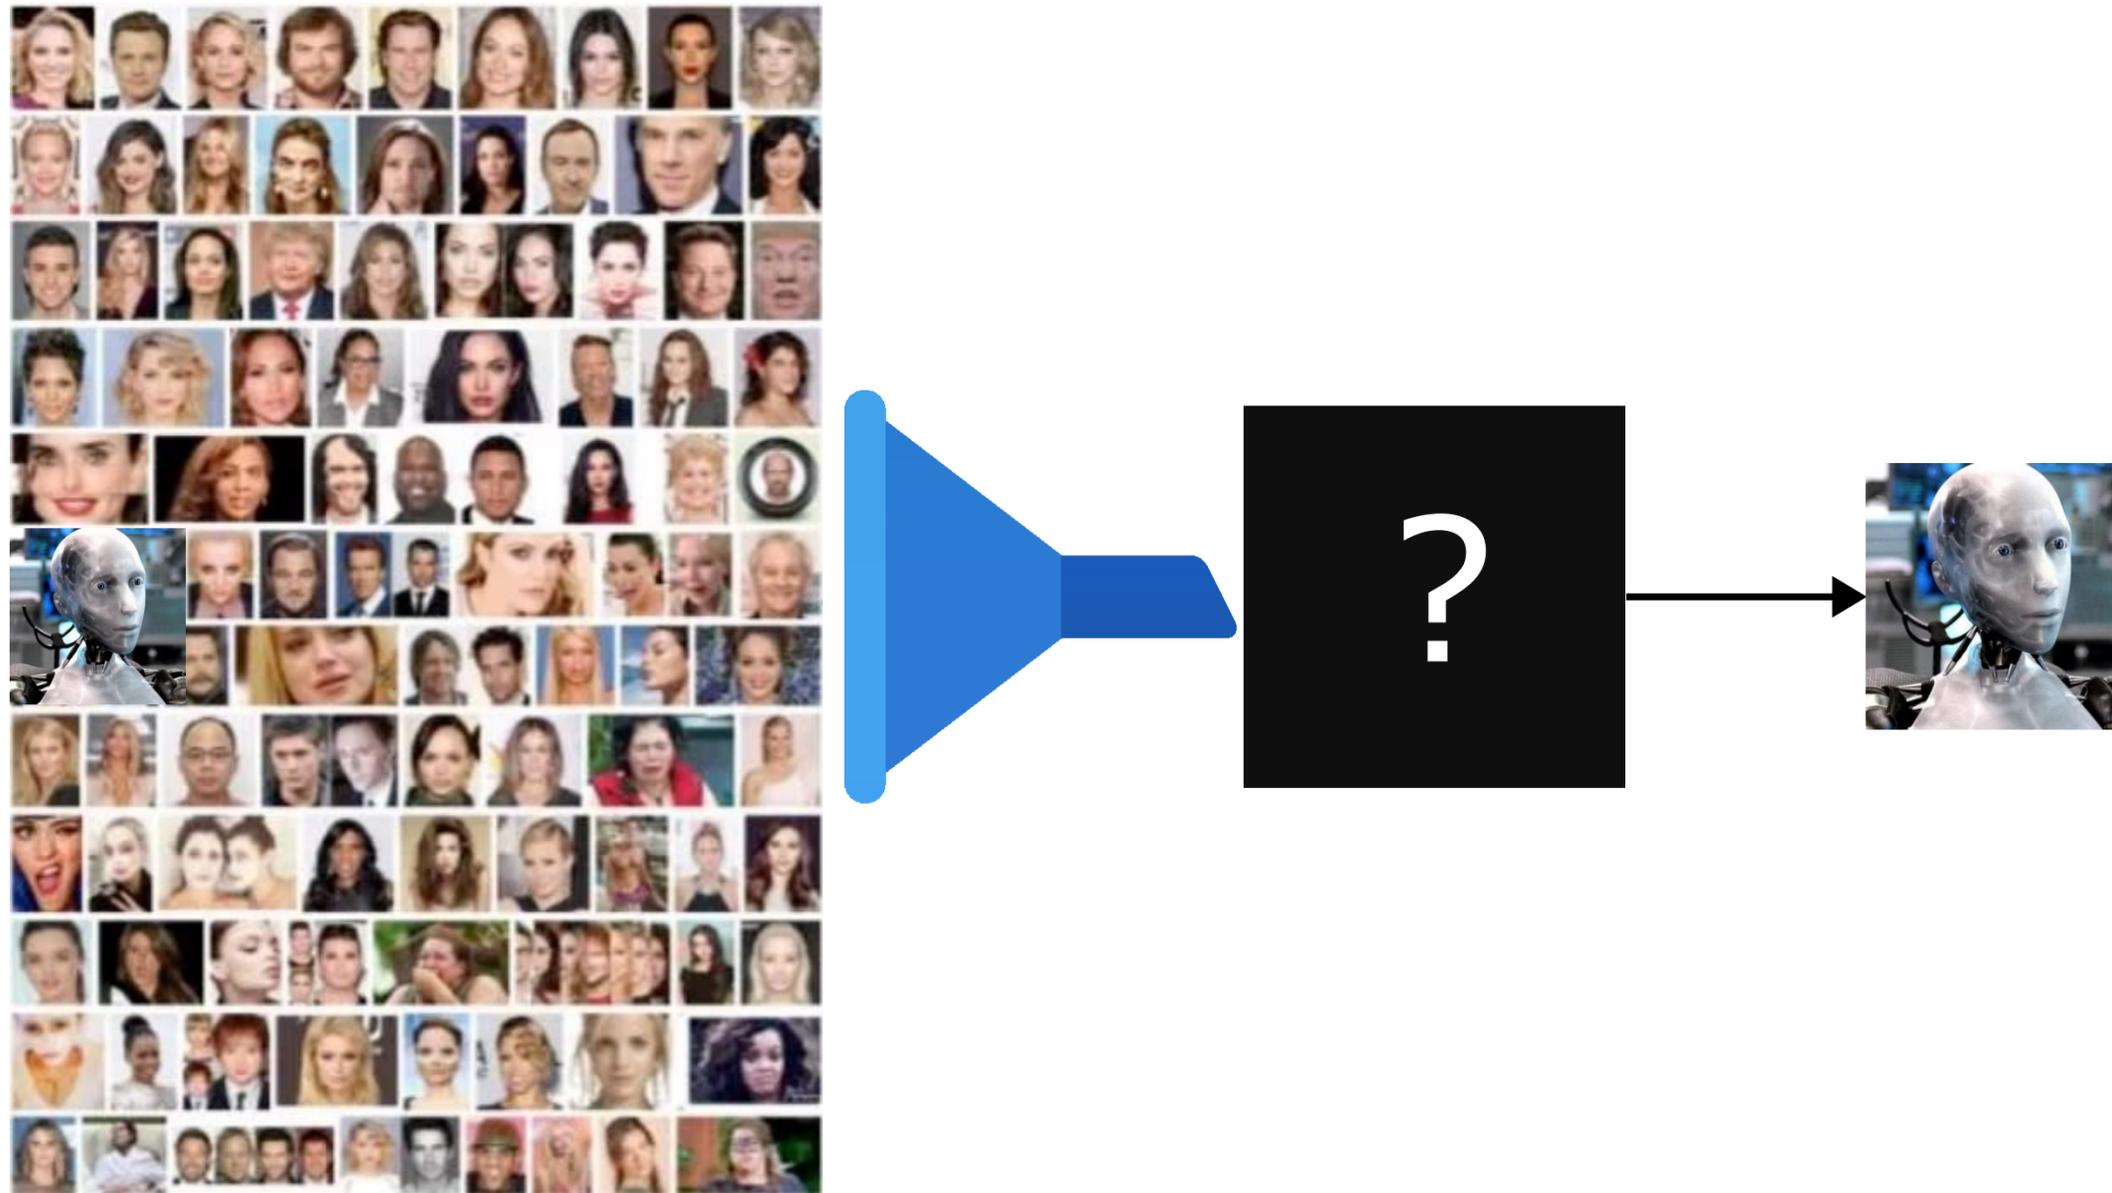
Tipo: No Supervisado.

Modelos:

- K-Means.
- Hierarchical Clustering.
- Mean Shift.
- DBSCAN.
- Spectral Clustering.

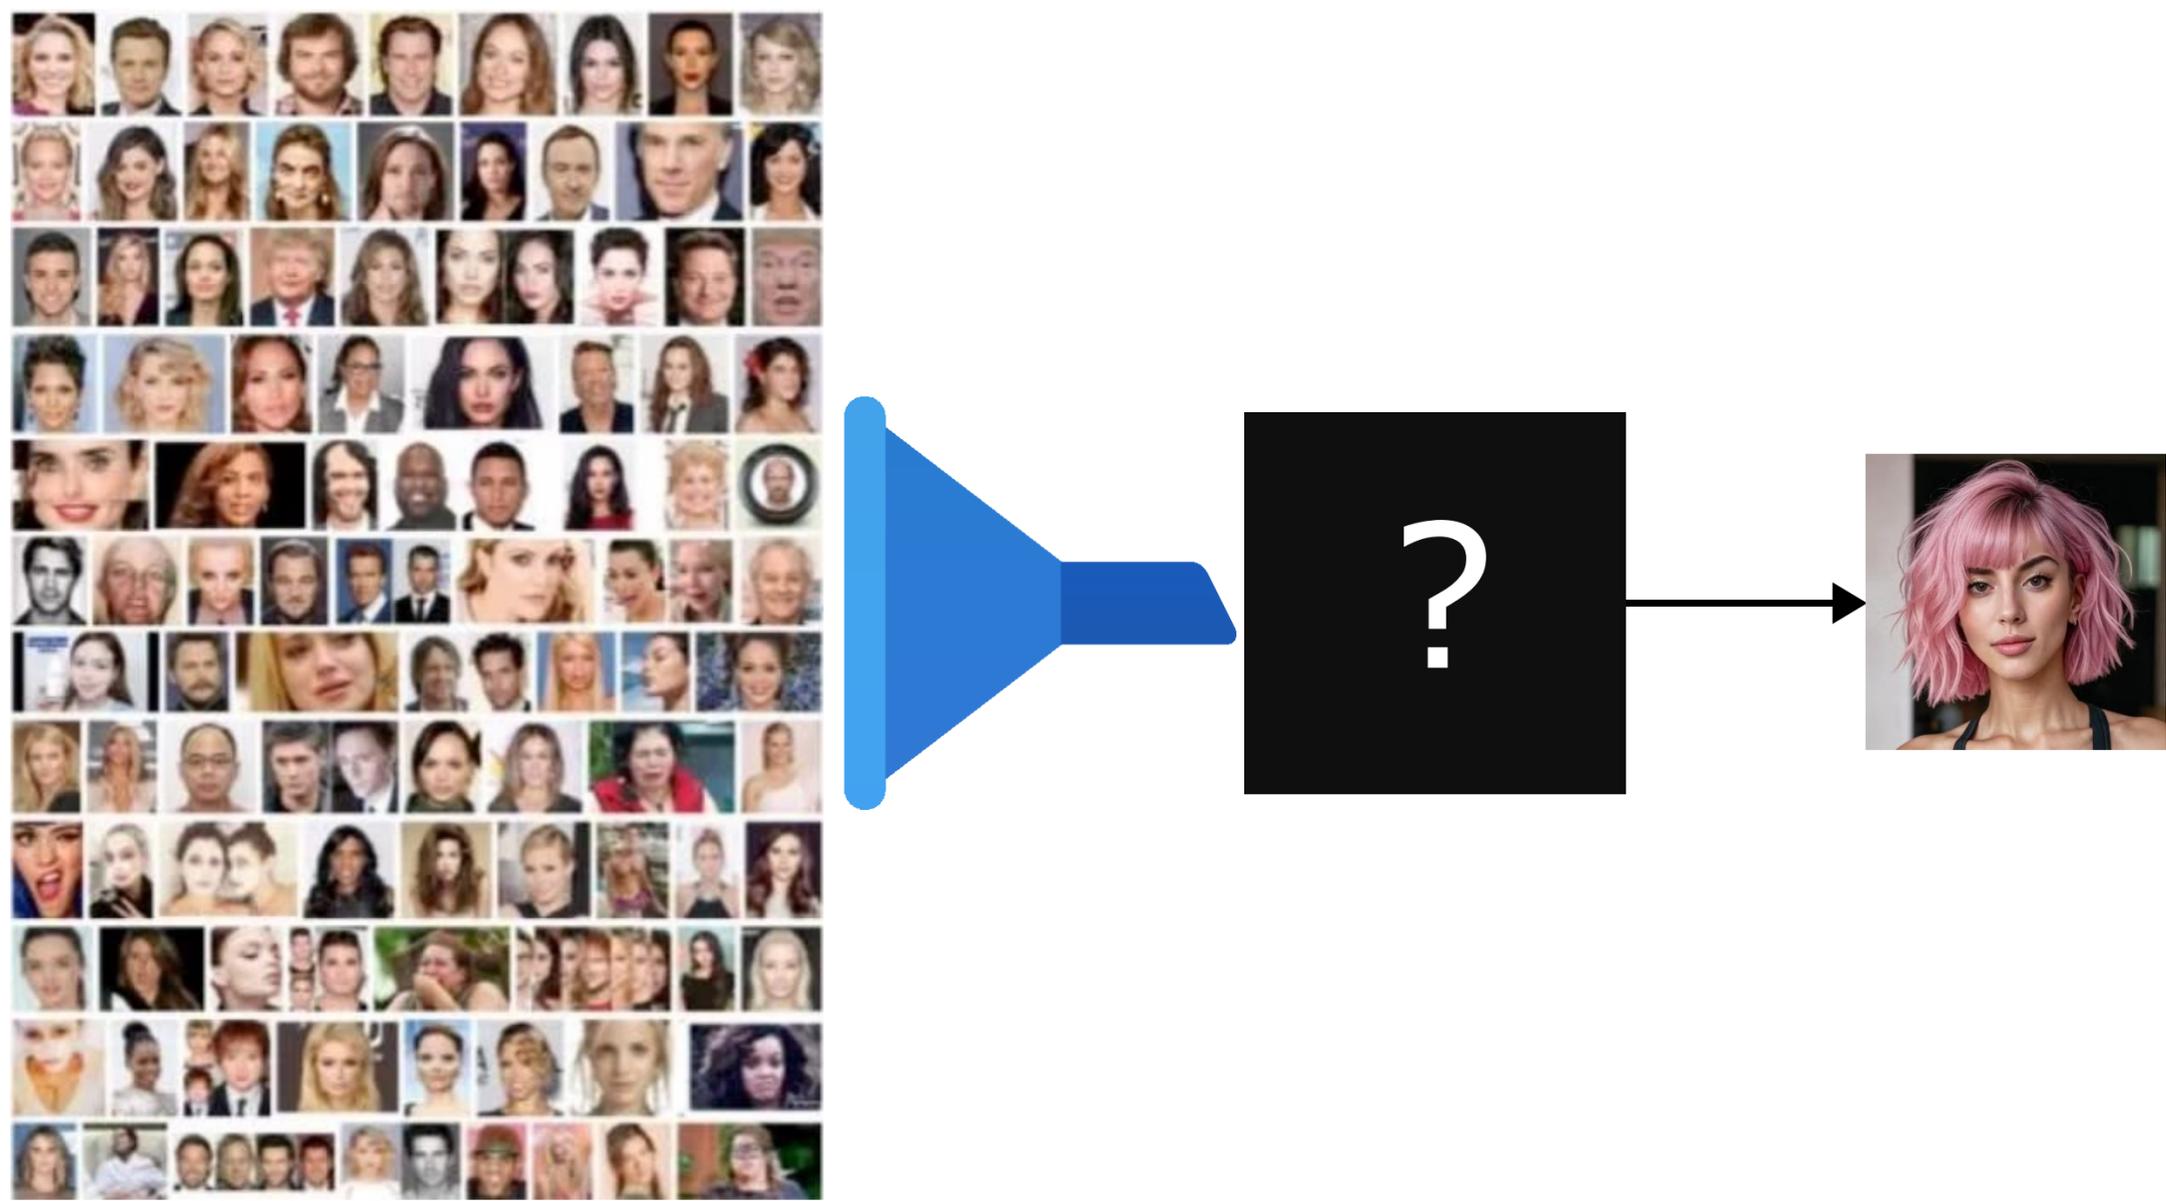
Tareas

Detección de Anomalías



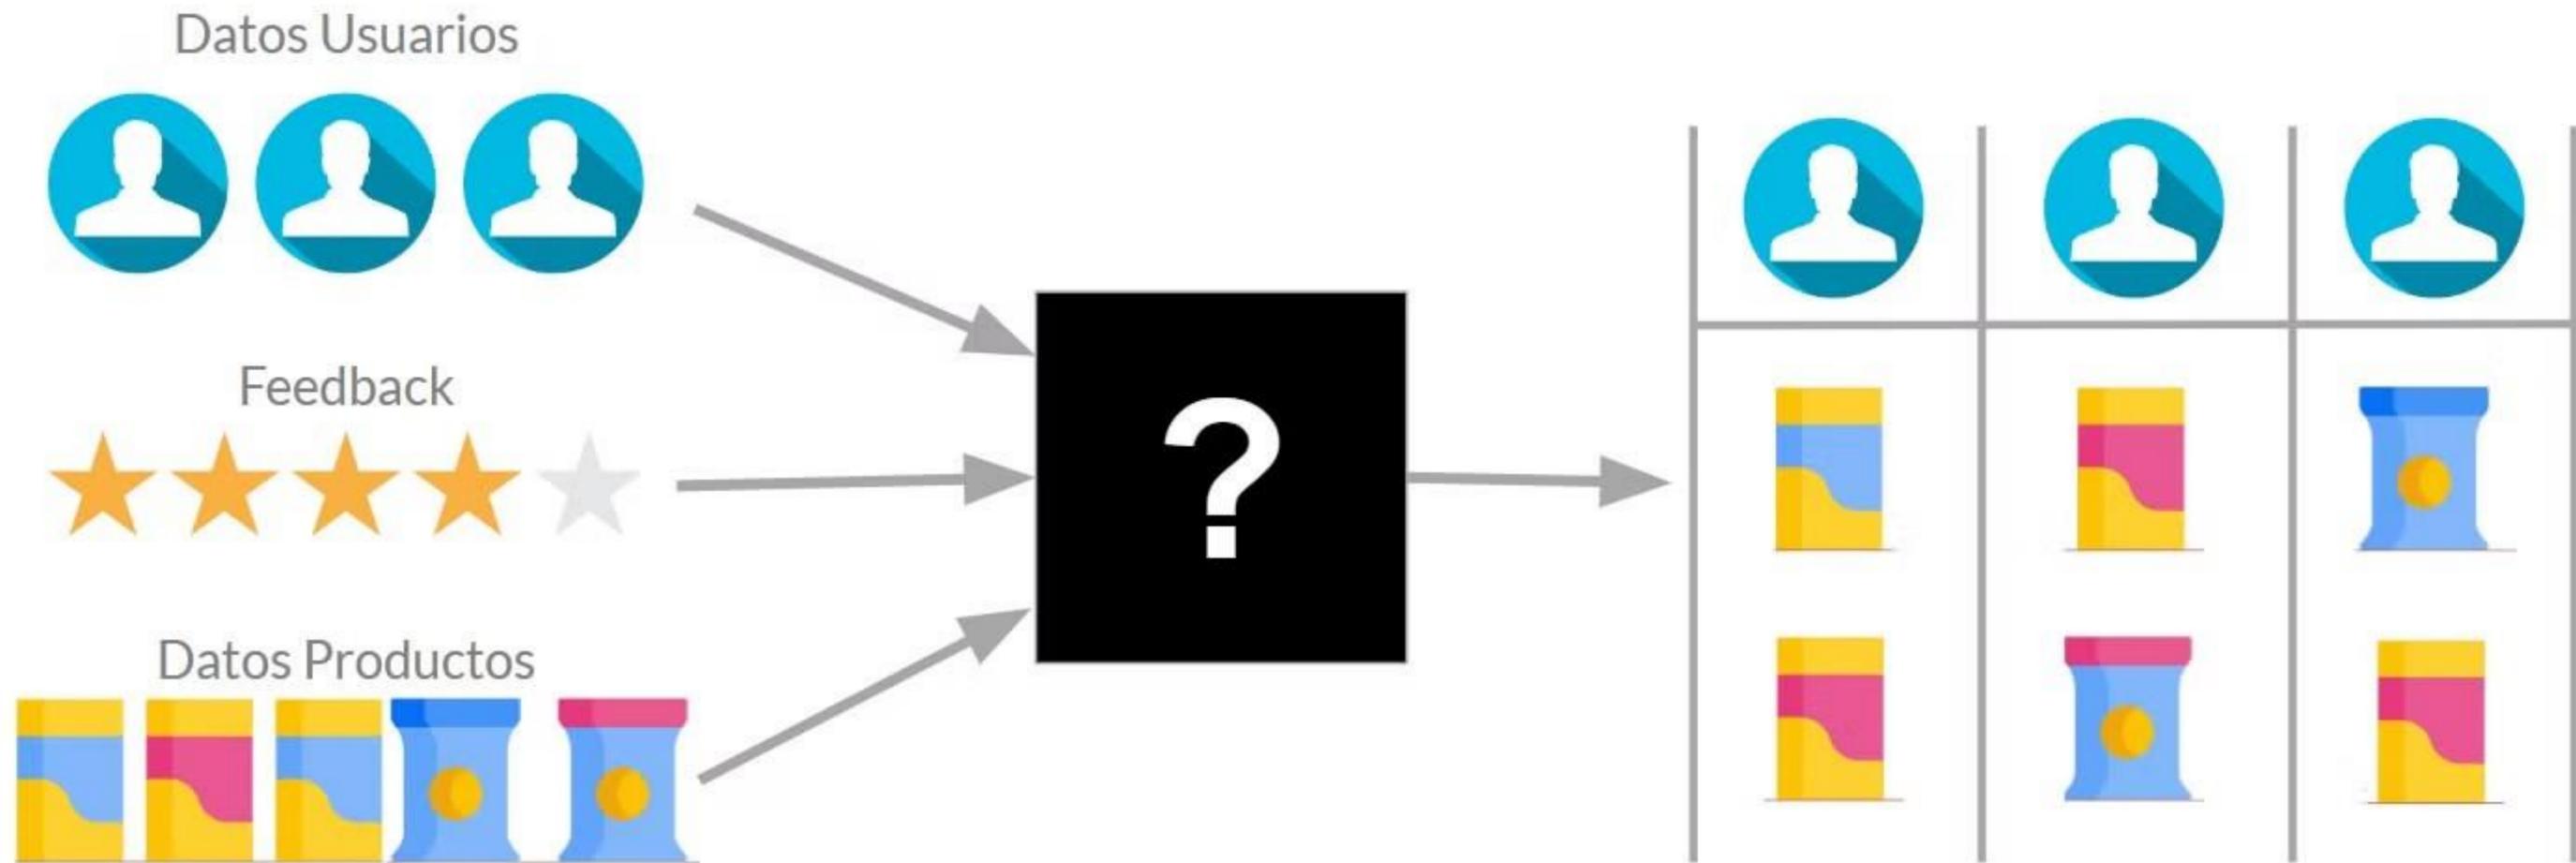
Tareas

Generación



Tareas

Recomendación



Paradigmas de aprendizaje

Modelos

Detección de Anomalías

Tipo: Supervisado / No Supervisado.

Modelos:

- Isolation Fores.
- Autoencoders.
- Local Outlier Factor (LOF).
- DBSCAN (Density-Based Spatial Clustering of Applications with Noise).

Generación

Tipo: Supervisado / No Supervisado.

Modelos:

- Isolation Fores.
- Autoencoders.
- DBSCAN (Density-Based Spatial Clustering of Applications with Noise).

Recomendación

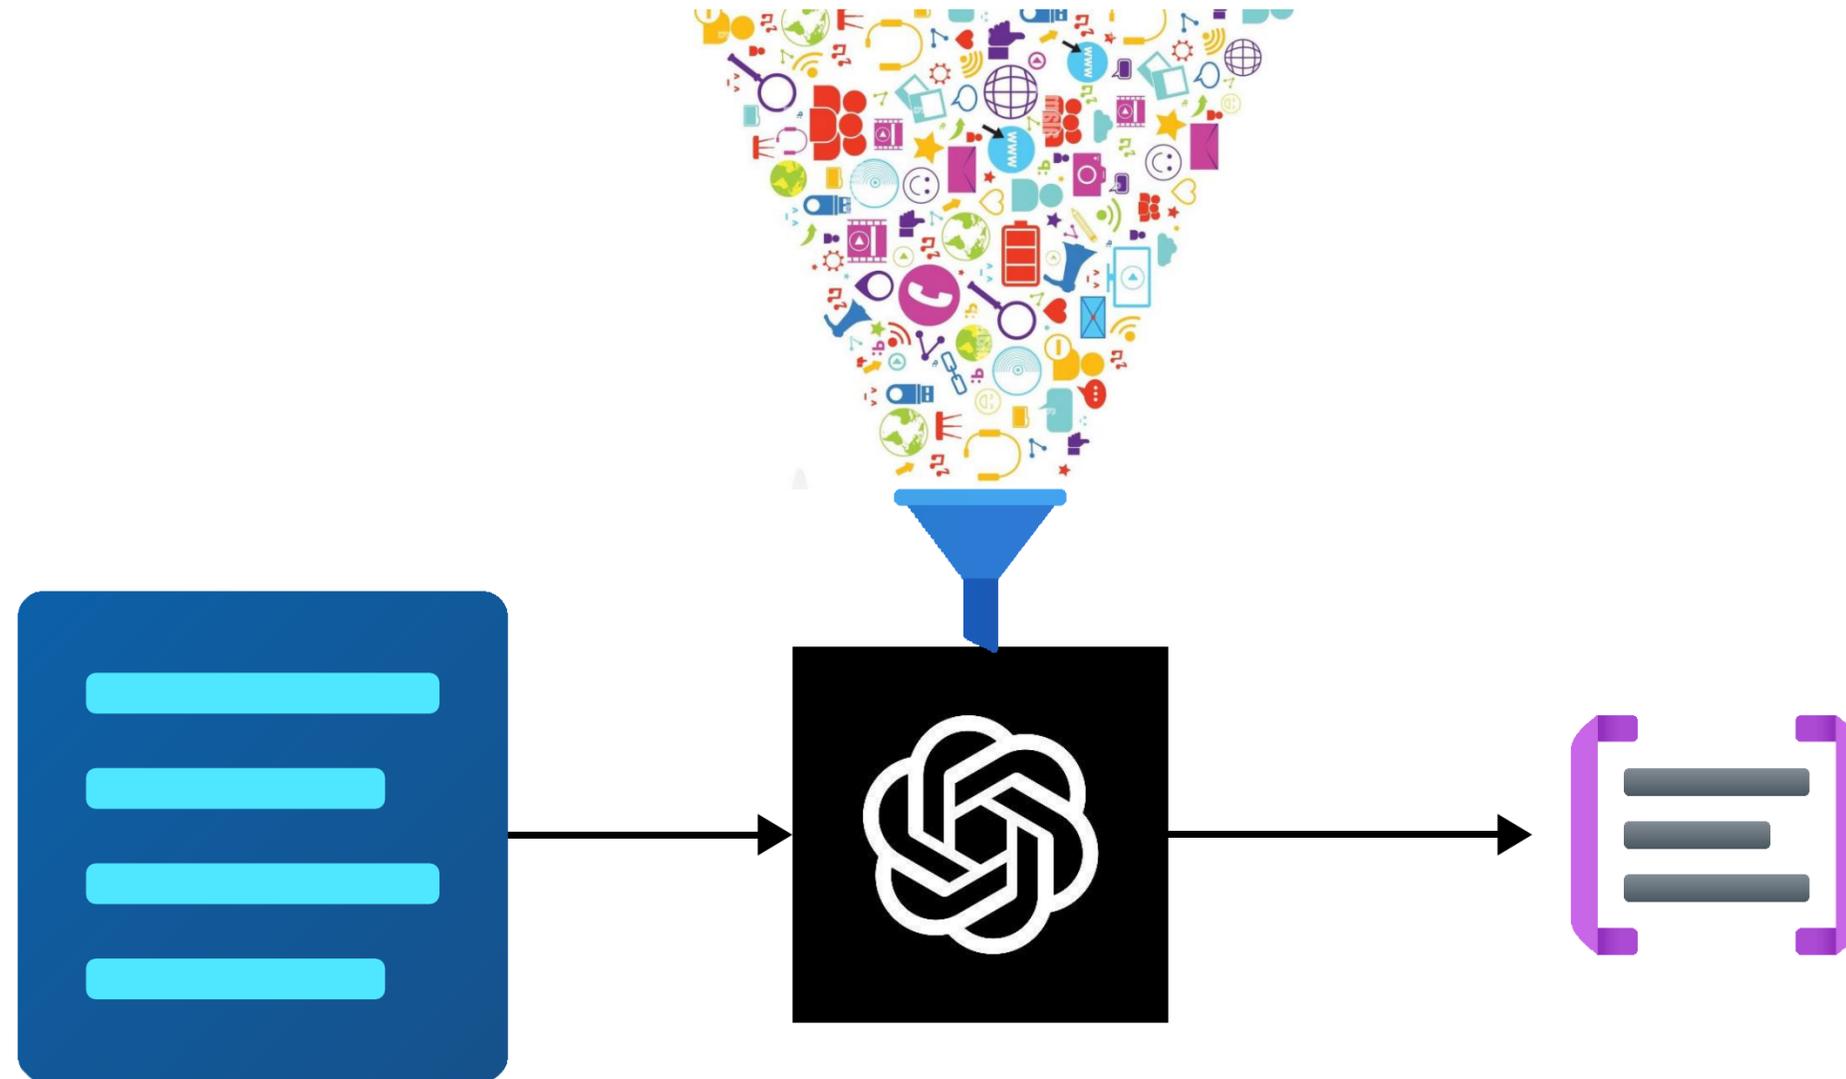
Tipo: Supervisado / No Supervisado.

Modelos:

- Variational Autoencoders (VAEs).
- Transformers.
- Generative Adversarial Networks (GANs).
- GPT (Generative Pre-trained Transformer).

Tareas

Large Language Models (LLM)



EJEMPLO PRÁCTICO



Conclusiones

Conclusión

Resumen y conclusiones



Conoce tus Datos y Problemas: Entender los datos y el problema que enfrentas es crucial para elegir el paradigma de aprendizaje más adecuado.



Practica con Aplicaciones Conocidas: Practica con algoritmos a problemas comunes, como la clasificación de imágenes o la recomendación de productos, para ganar experiencia práctica.



Empieza con lo Esencial: Aprende los fundamentos, como la importancia de las características y los algoritmos básicos, para construir una base sólida en Machine Learning.



Gracias por su atención ¿Dudas?