



Facultad de Ingeniería, UDELAR

JUCC 2025

Algoritmo evolutivo y redes
generativas antagónicas para
mejorar la clasificación de conjuntos
de datos parcialmente etiquetados

Franco Ferrari
Sergio Nesmachnow
Jamal Toutouh






Problema

PROBLEMA

Muchos modelos de aprendizaje automático son utilizados para problemas de clasificación.

Modelos de clasificación suelen presentar fallas e inestabilidad en su entrenamiento al disponer de pocos datos etiquetados.





Perro?
Gato?
Oso?
Oveja?
Real?



Motivación

MOTIVACIÓN

- Modelos con pocos datos etiquetados fallan en su entrenamiento.
- Muchos escenarios con abundantes datos no etiquetados y muy pocos etiquetados.
- El proceso de etiquetado es muchas veces inviable y/o costoso.




MOTIVACIÓN

Caso Práctico

Sistema hospitalario de USA necesita un sistema de clasificación automática de tomografías de cráneo en emergencias, priorizando casos con hemorragia intracraneal.

- Profesional = 200 USD x hora
- Tiempo de etiquetado por tomografía = 20 min
- Costo por tomografía 66.666... USD.

Entrenamiento supervisado	Entrenamiento semi-supervisado
10.000 imágenes etiquetadas 667.000 USD 3.333 horas	100 imágenes etiquetadas 6.670 USD 33.3 horas







Aportes

APORTES

- Uso de GANs entrenadas con pocos datos etiquetados y una mayor proporción de datos sin etiquetar.
- Arquitectura que utiliza técnicas del estado del arte capaz de ser entrenada con pocos datos etiquetados.
- Hibridación con algoritmos evolutivos (AEs) para mejores resultados y mayor robustez en el entrenamiento.



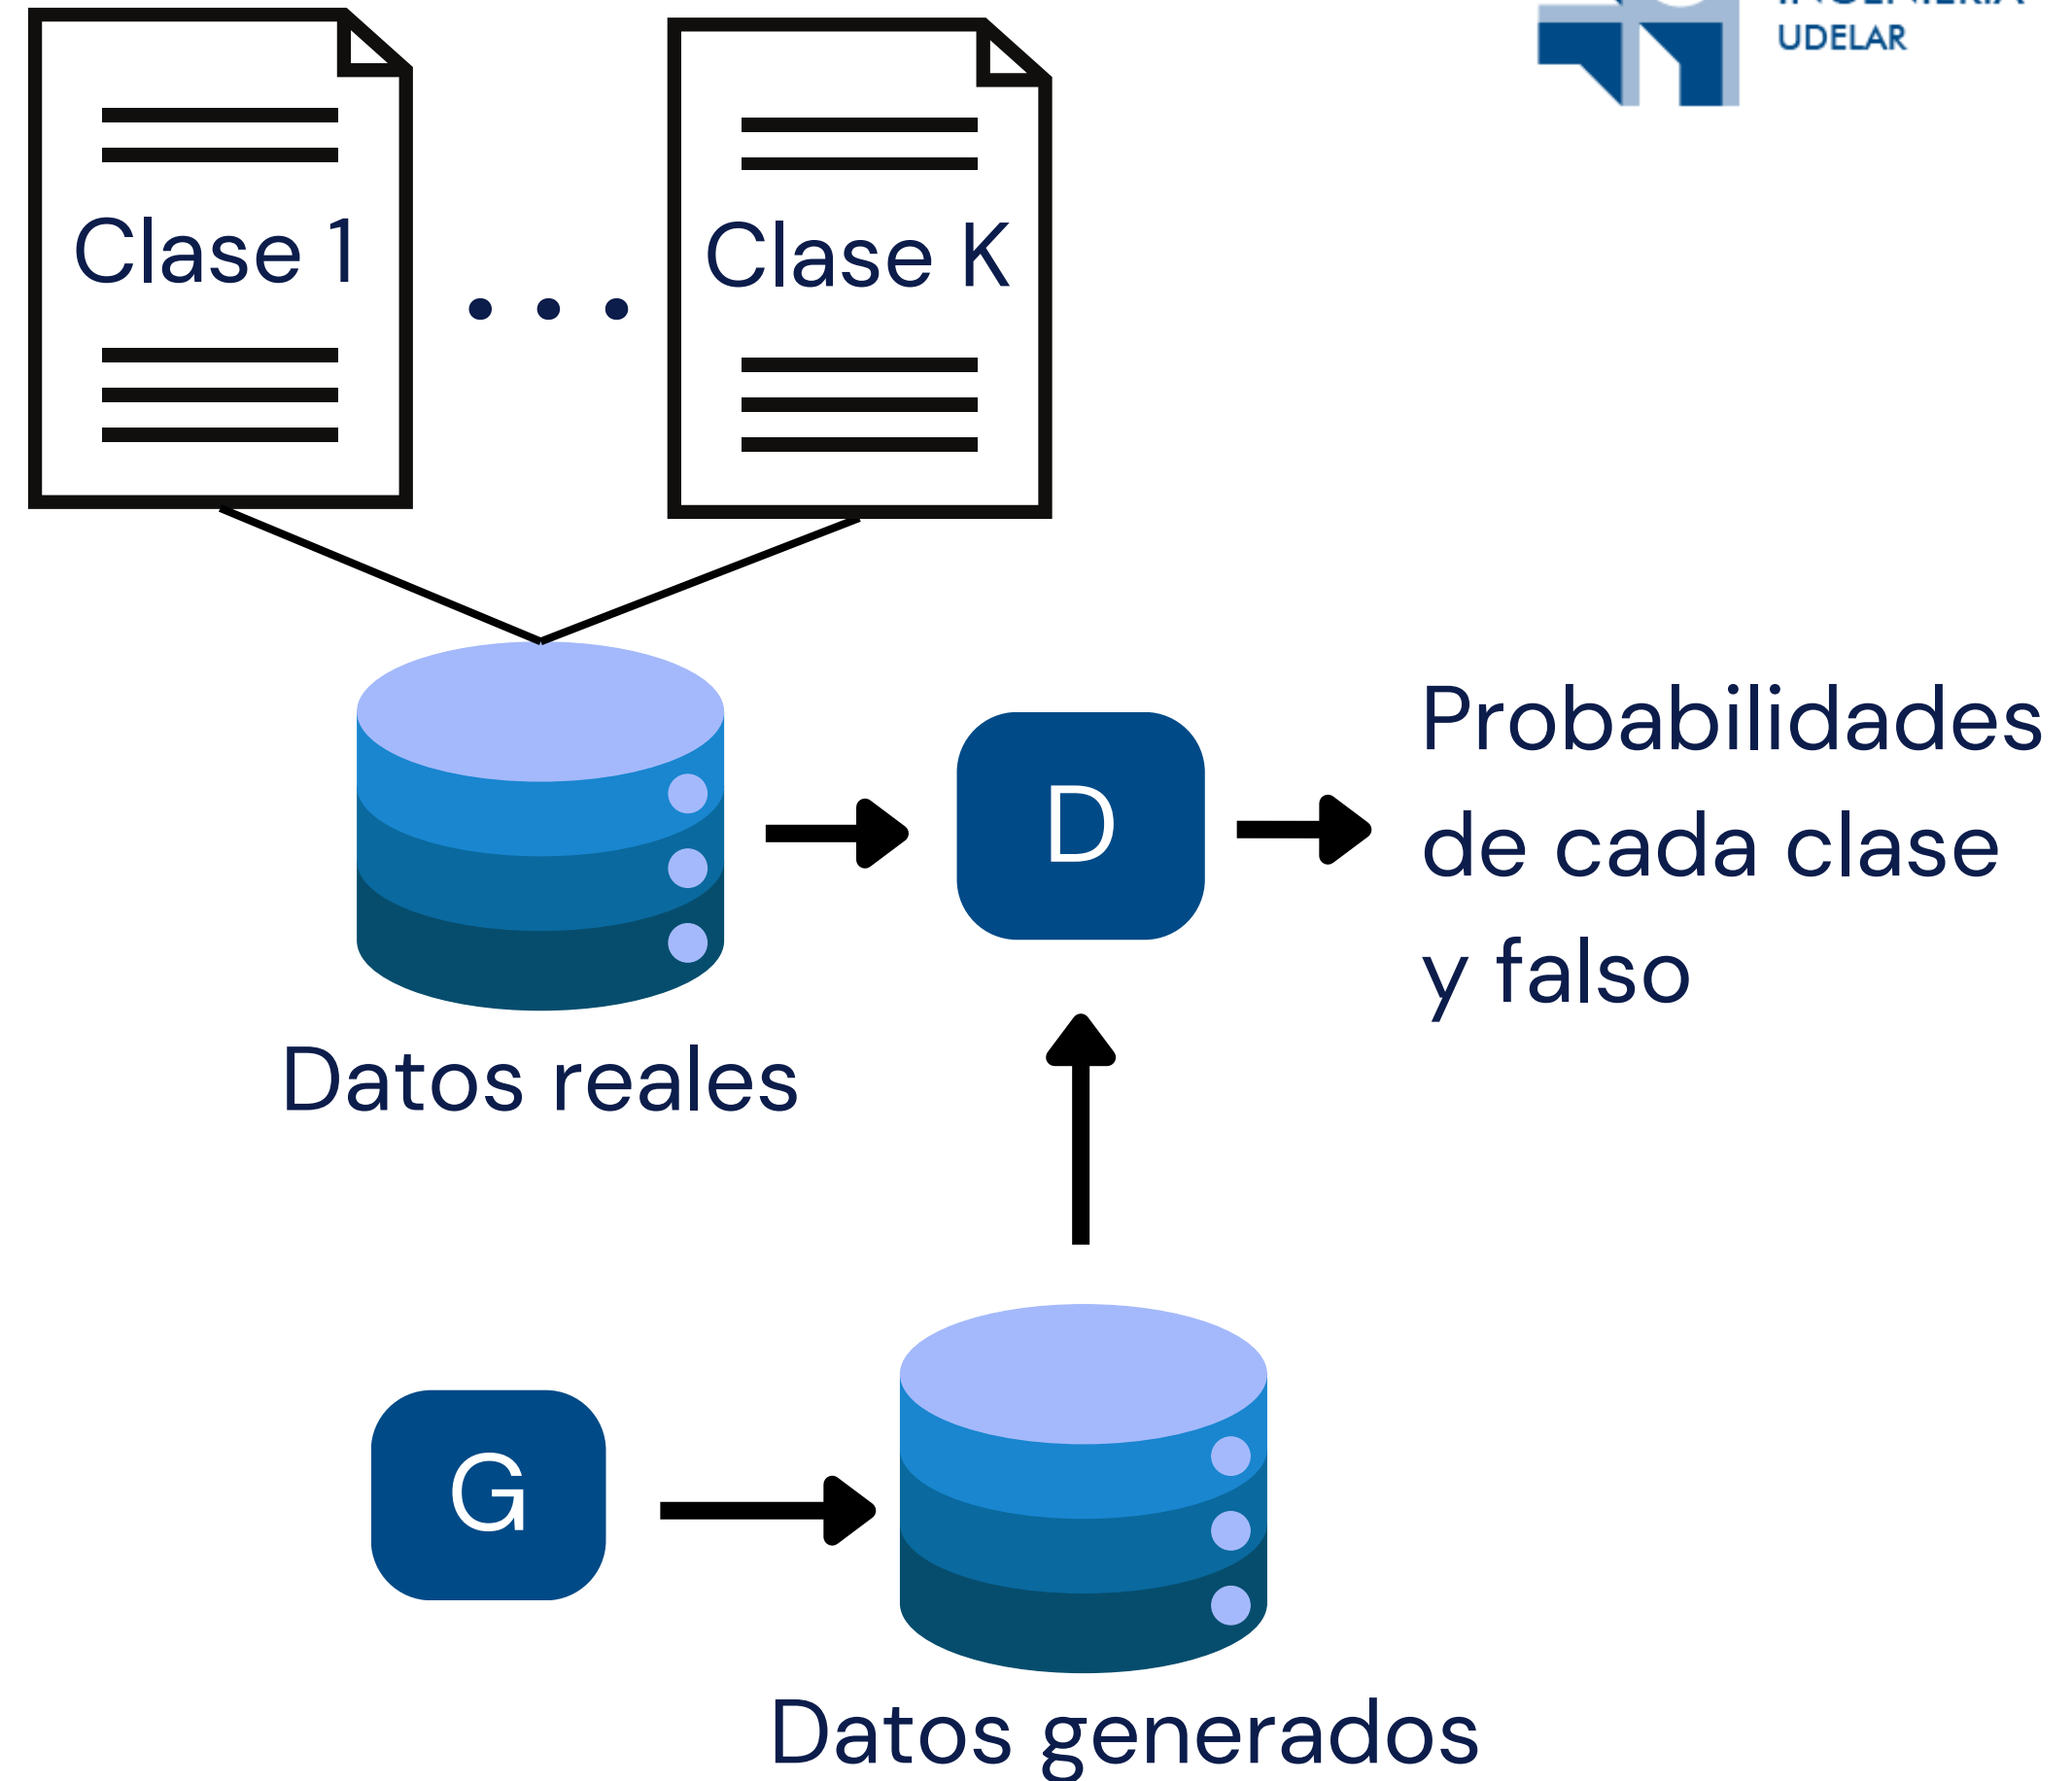
The background is a solid dark blue. In the top-left corner, there is a cluster of overlapping shapes: a large orange circle, a smaller blue circle, and a thick orange ring. In the bottom-right corner, there is another cluster: a small orange circle, a larger orange circle, a blue circle, and a circle with orange and blue diagonal stripes. The text is centered in the middle of the image.

Redes neuronales generativas antagónicas (GANs)

GANs

- Generador (G)
- Discriminador (D)

Entrenamiento adversarial:
ambas redes tienen objetivos
antagónicos. El buen desempeño
de una red implica el mal
desempeño de la otra.



GAN CONVOLUCIONAL

- Uso de redes neuronales convolucionales (CNN)
- Capas adicionales: batch normalization, dropout, leaky ReLU.

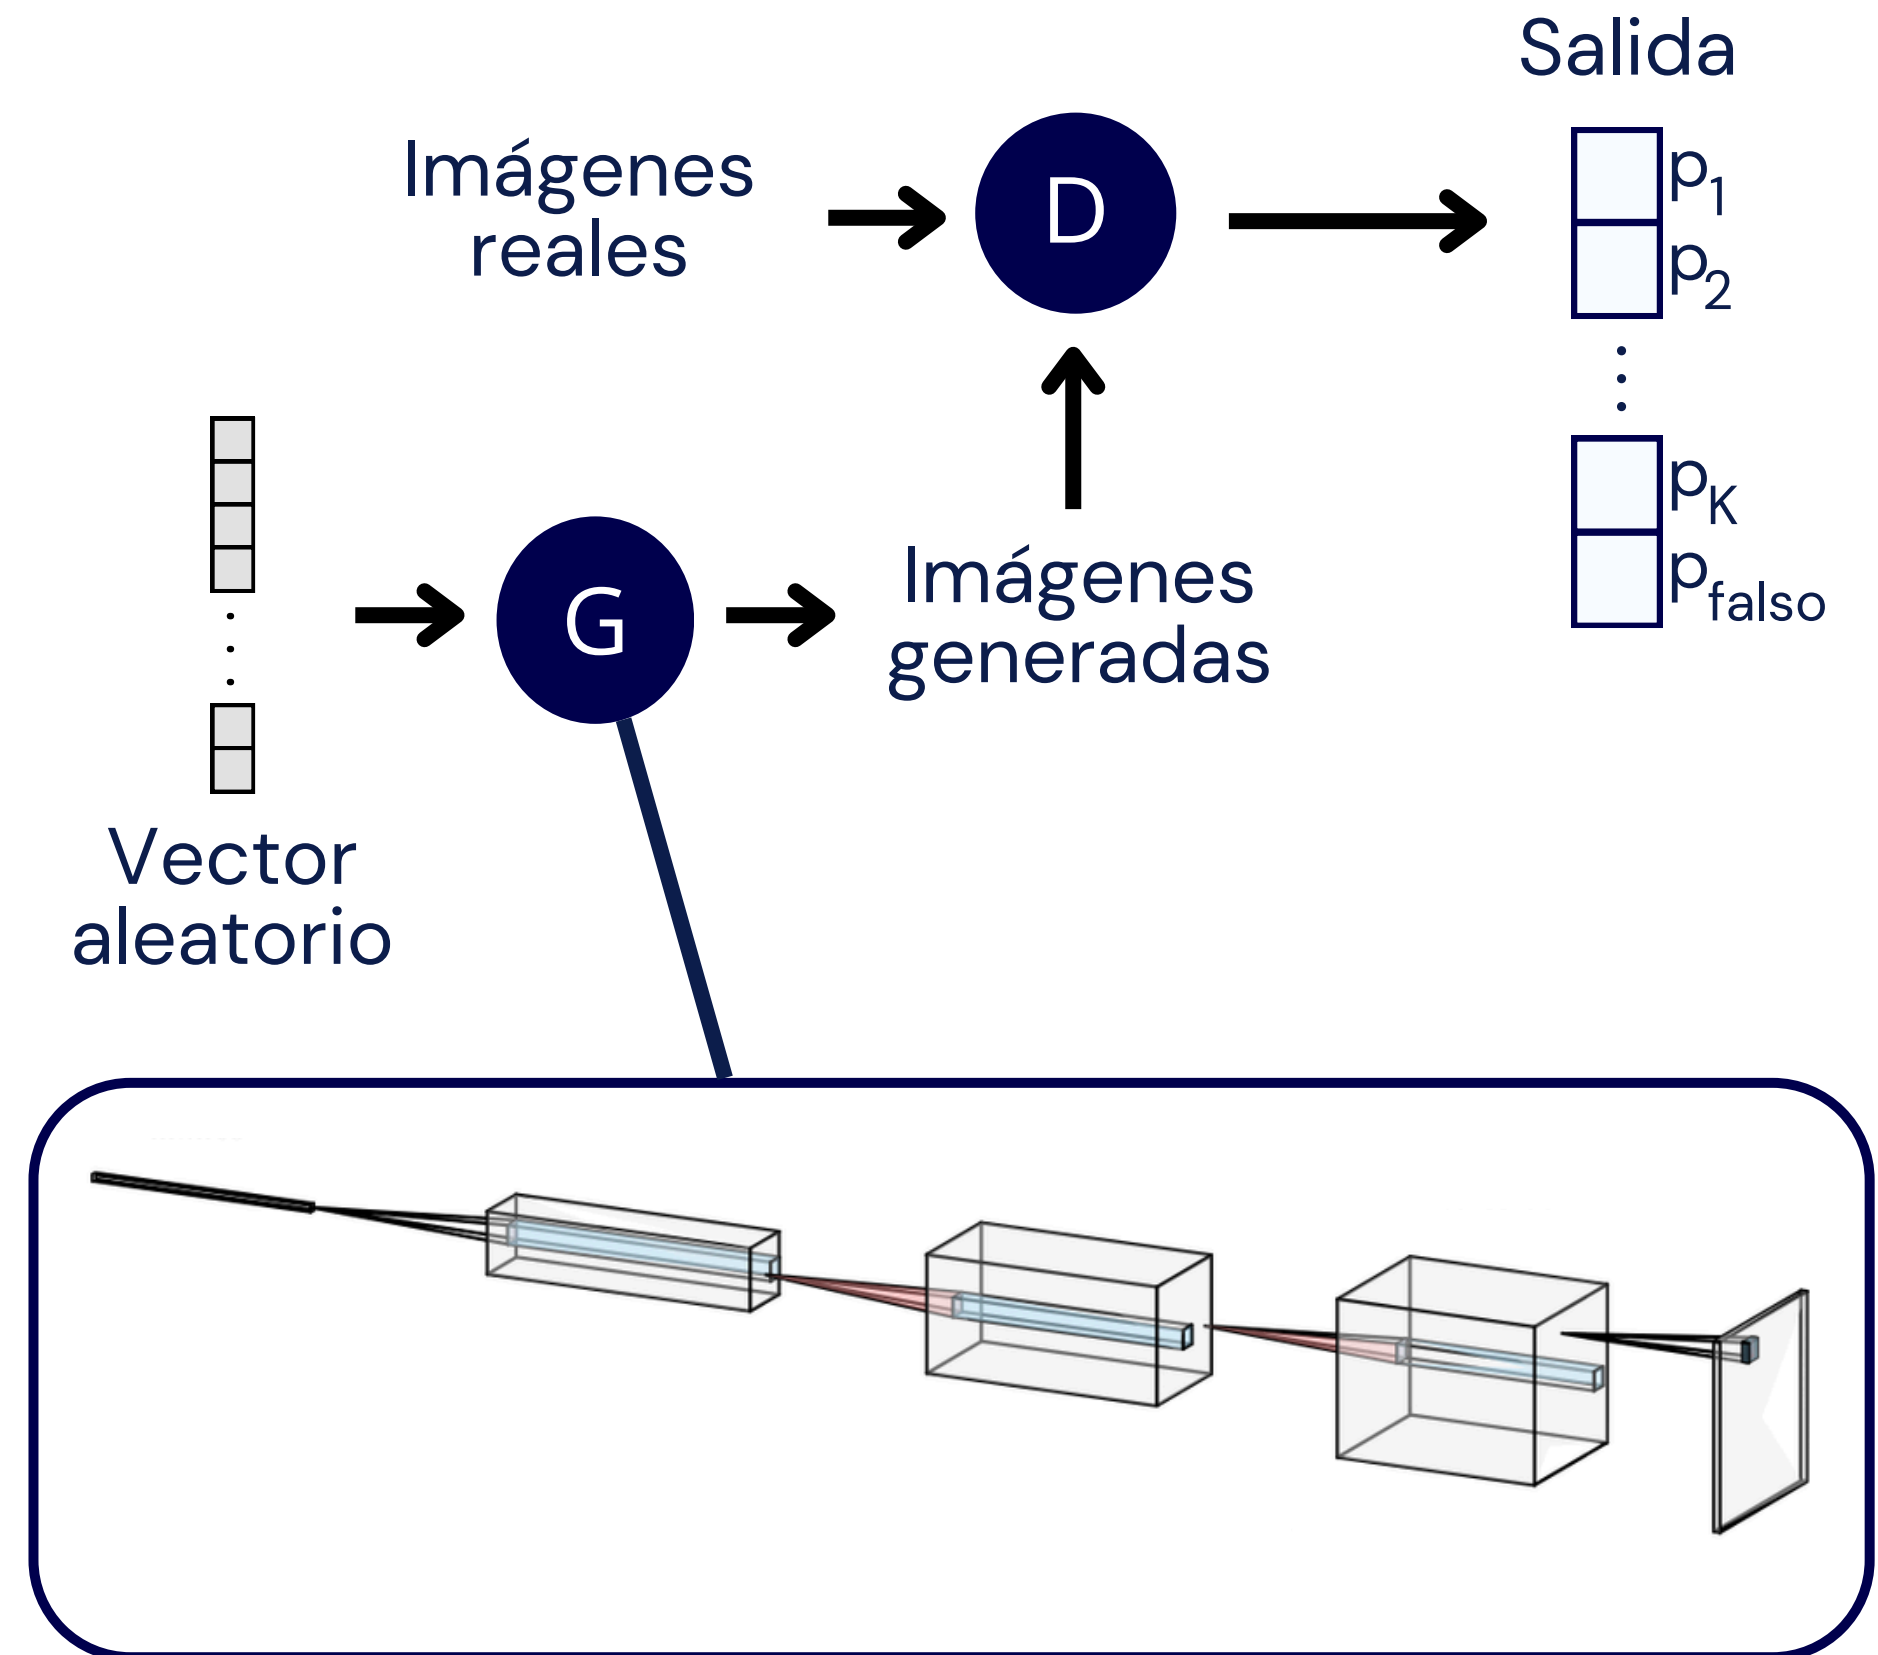
- Loss del discriminador:

$$L_D = L_{\text{supervisado}} + L_{\text{no-supervisado}}$$

$$L_{\text{no-supervisado}} = L_{\text{no-etiquetado}} + L_{\text{falso}}$$

- Loss del generador:

$$L_G = L_{\text{calidad}} + \gamma L_{\text{diversidad}}$$



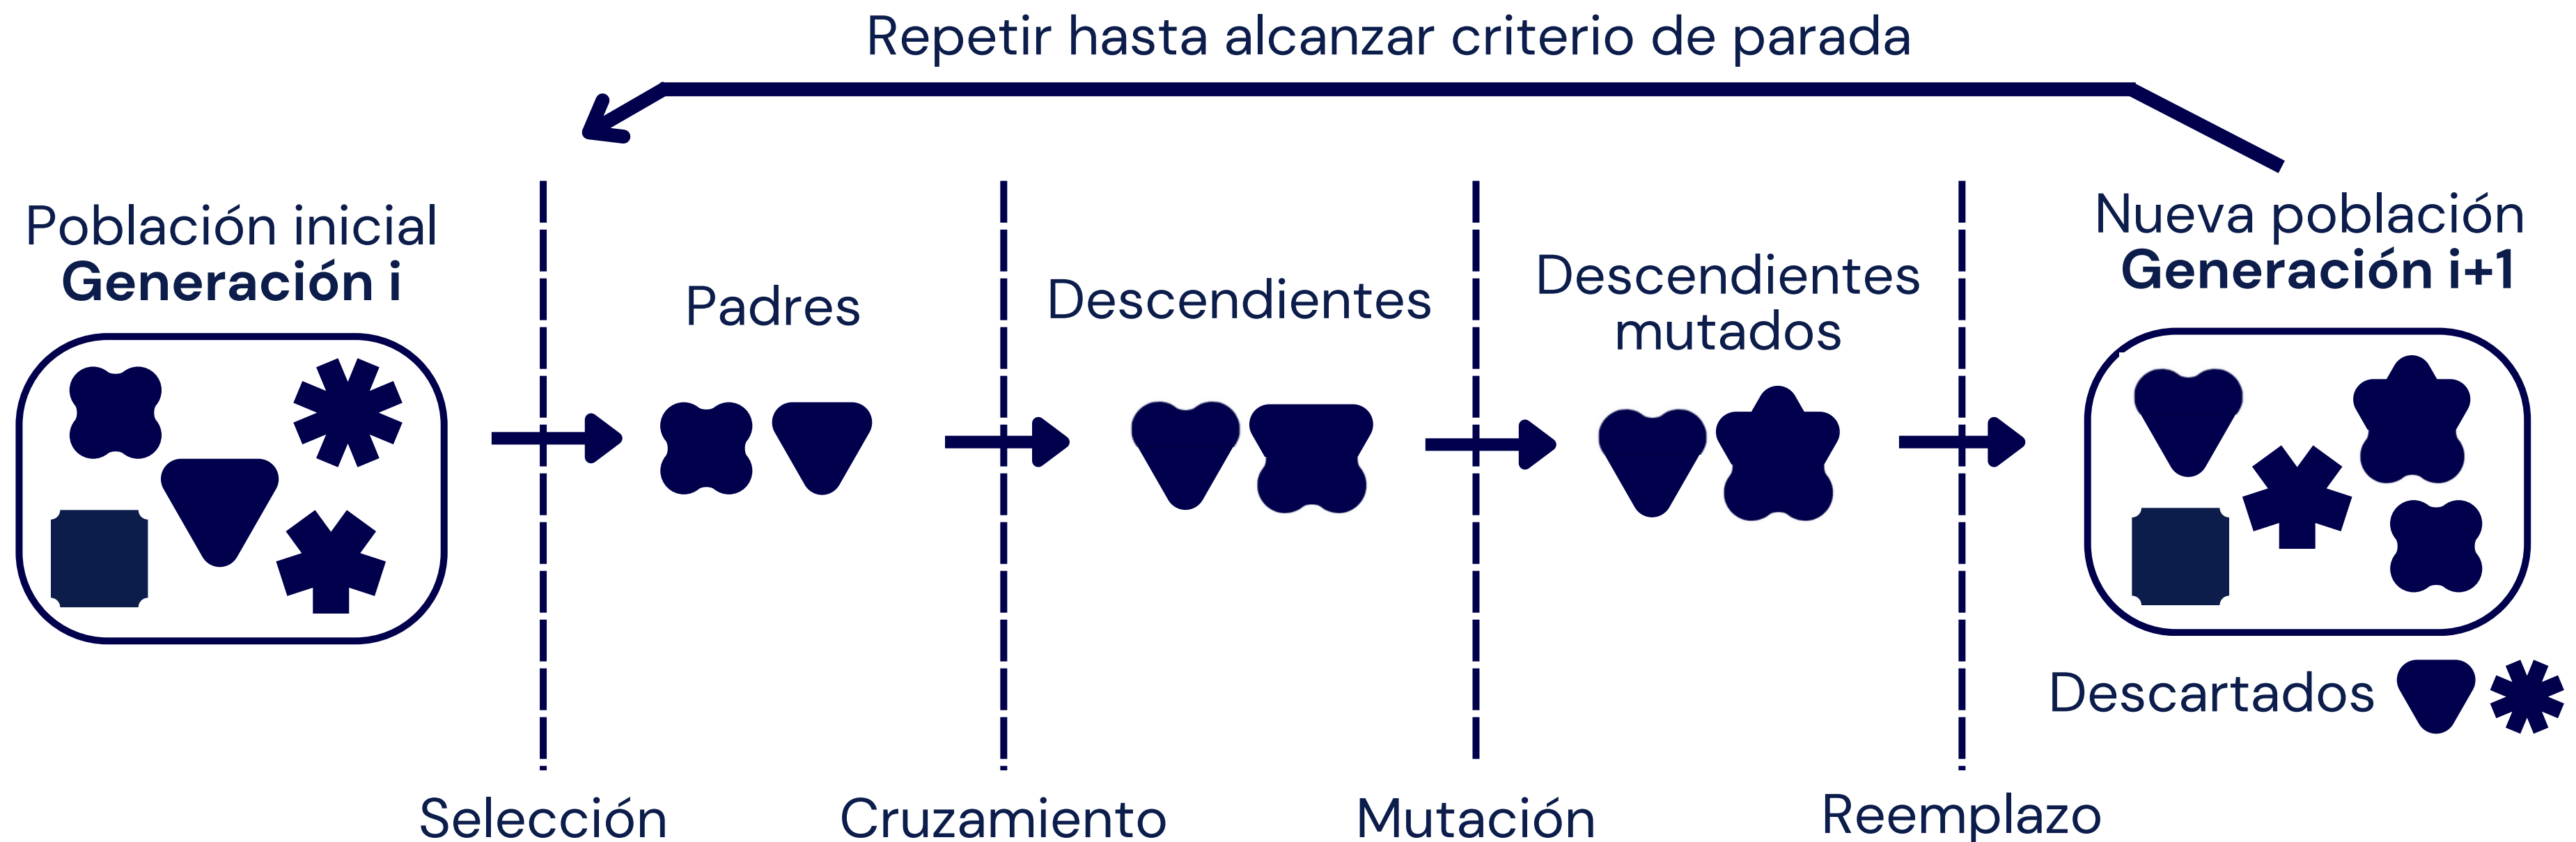


Algoritmos evolutivos (AEs)




AEs

- Basados en la evolución de los seres vivos.
- Población de individuos evaluados mediante su aptitud.
- Proceso iterativo. Operadores de selección, cruzamiento, mutación y reemplazo.



Hibridación con AEs


- Se enfrenta una población de generadores versus una de discriminadores.
- Multi-objetivo (MOEA): Dos funciones objetivo. Se utiliza el algoritmo Non-Dominated Sorting Genetic Algorithm II (NSGA-II).



OBJETIVOS UTILIZADOS


Generadores	Discriminadores
$F_{calidad}(G_i) = \frac{1}{ P_D } \left(\sum_{j=1}^{ P_D } L_{calidad}(G_i, D_j) \right)$ $F_{diversidad}(G_i) = \frac{1}{ P_D } \left(\sum_{j=1}^{ P_D } L_{diversidad}(G_i, D_j) \right)$	$L_{supervisado}$ $F_{no-supervisado}(D_i) = L_{no-etiquetado}(D_i) + F_{falso}(D_i)$

Ejemplo para calidad generadores:




$$F_{falso}(D_i) = \frac{1}{|P_G|} \left(\sum_{j=1}^{|P_G|} L_{falso}(G_j, D_i) \right)$$

AE PROPUESTO




1 – Inicialización

- Inicialización aleatoria.
- Emparejamiento.
- Entrenamiento.




2 – Selección

- Seleccionar M aleatoriamente.
- Seleccionar K mediante NSGA-II.



3 – Cruzamiento

- Clonar padres.
- Emparejar.
- Entrenar.



4 – Reemplazo

- Reducir a P mediante NSGA-II.

The background is a solid dark blue. In the top-left corner, there is a cluster of overlapping shapes: a small light orange circle, a larger orange circle, a blue circle, and a circle with orange and blue diagonal stripes. In the bottom-right corner, there is another cluster: a small light orange circle, a larger orange circle, a blue circle, and a circle with orange and blue diagonal stripes. The word "Experimentación" is centered in the middle of the image in a white, bold, sans-serif font.

Experimentación

- [illegible]

FID

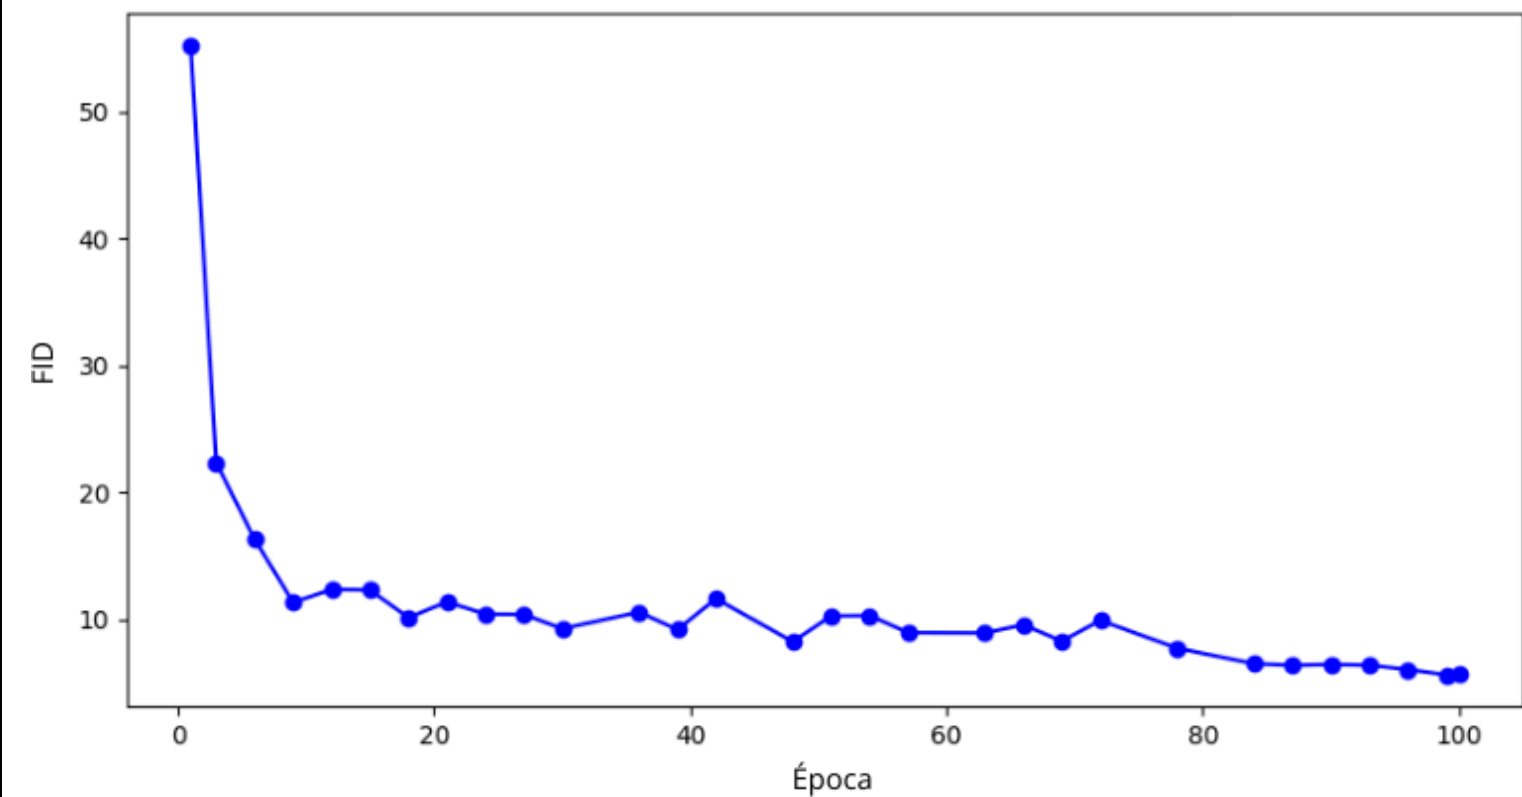
- Similares para todos los enfoques y escenarios con **medias ≈ 10** (buena calidad) y desvíos bajos.
- No hay diferencias significativas entre distribuciones.



Sin AE



MOEA




Ejemplo de descenso de FID

PRECISIÓN

Enfoque no evolutivo



- Medianas altas y desvíos altos.
- Más datos etiquetados resultan en medianas más altas y dispersiones más bajas.
- Muchos valores atípicos.



PRECISIÓN

MOEA

- Medias y medianas más altas y desvíos e IQRs más bajos.
- Más datos = mejores resultados.
- Escenarios de pocos datos con buenos resultados.
- Frentes de Pareto más poblados = Medias mayores.

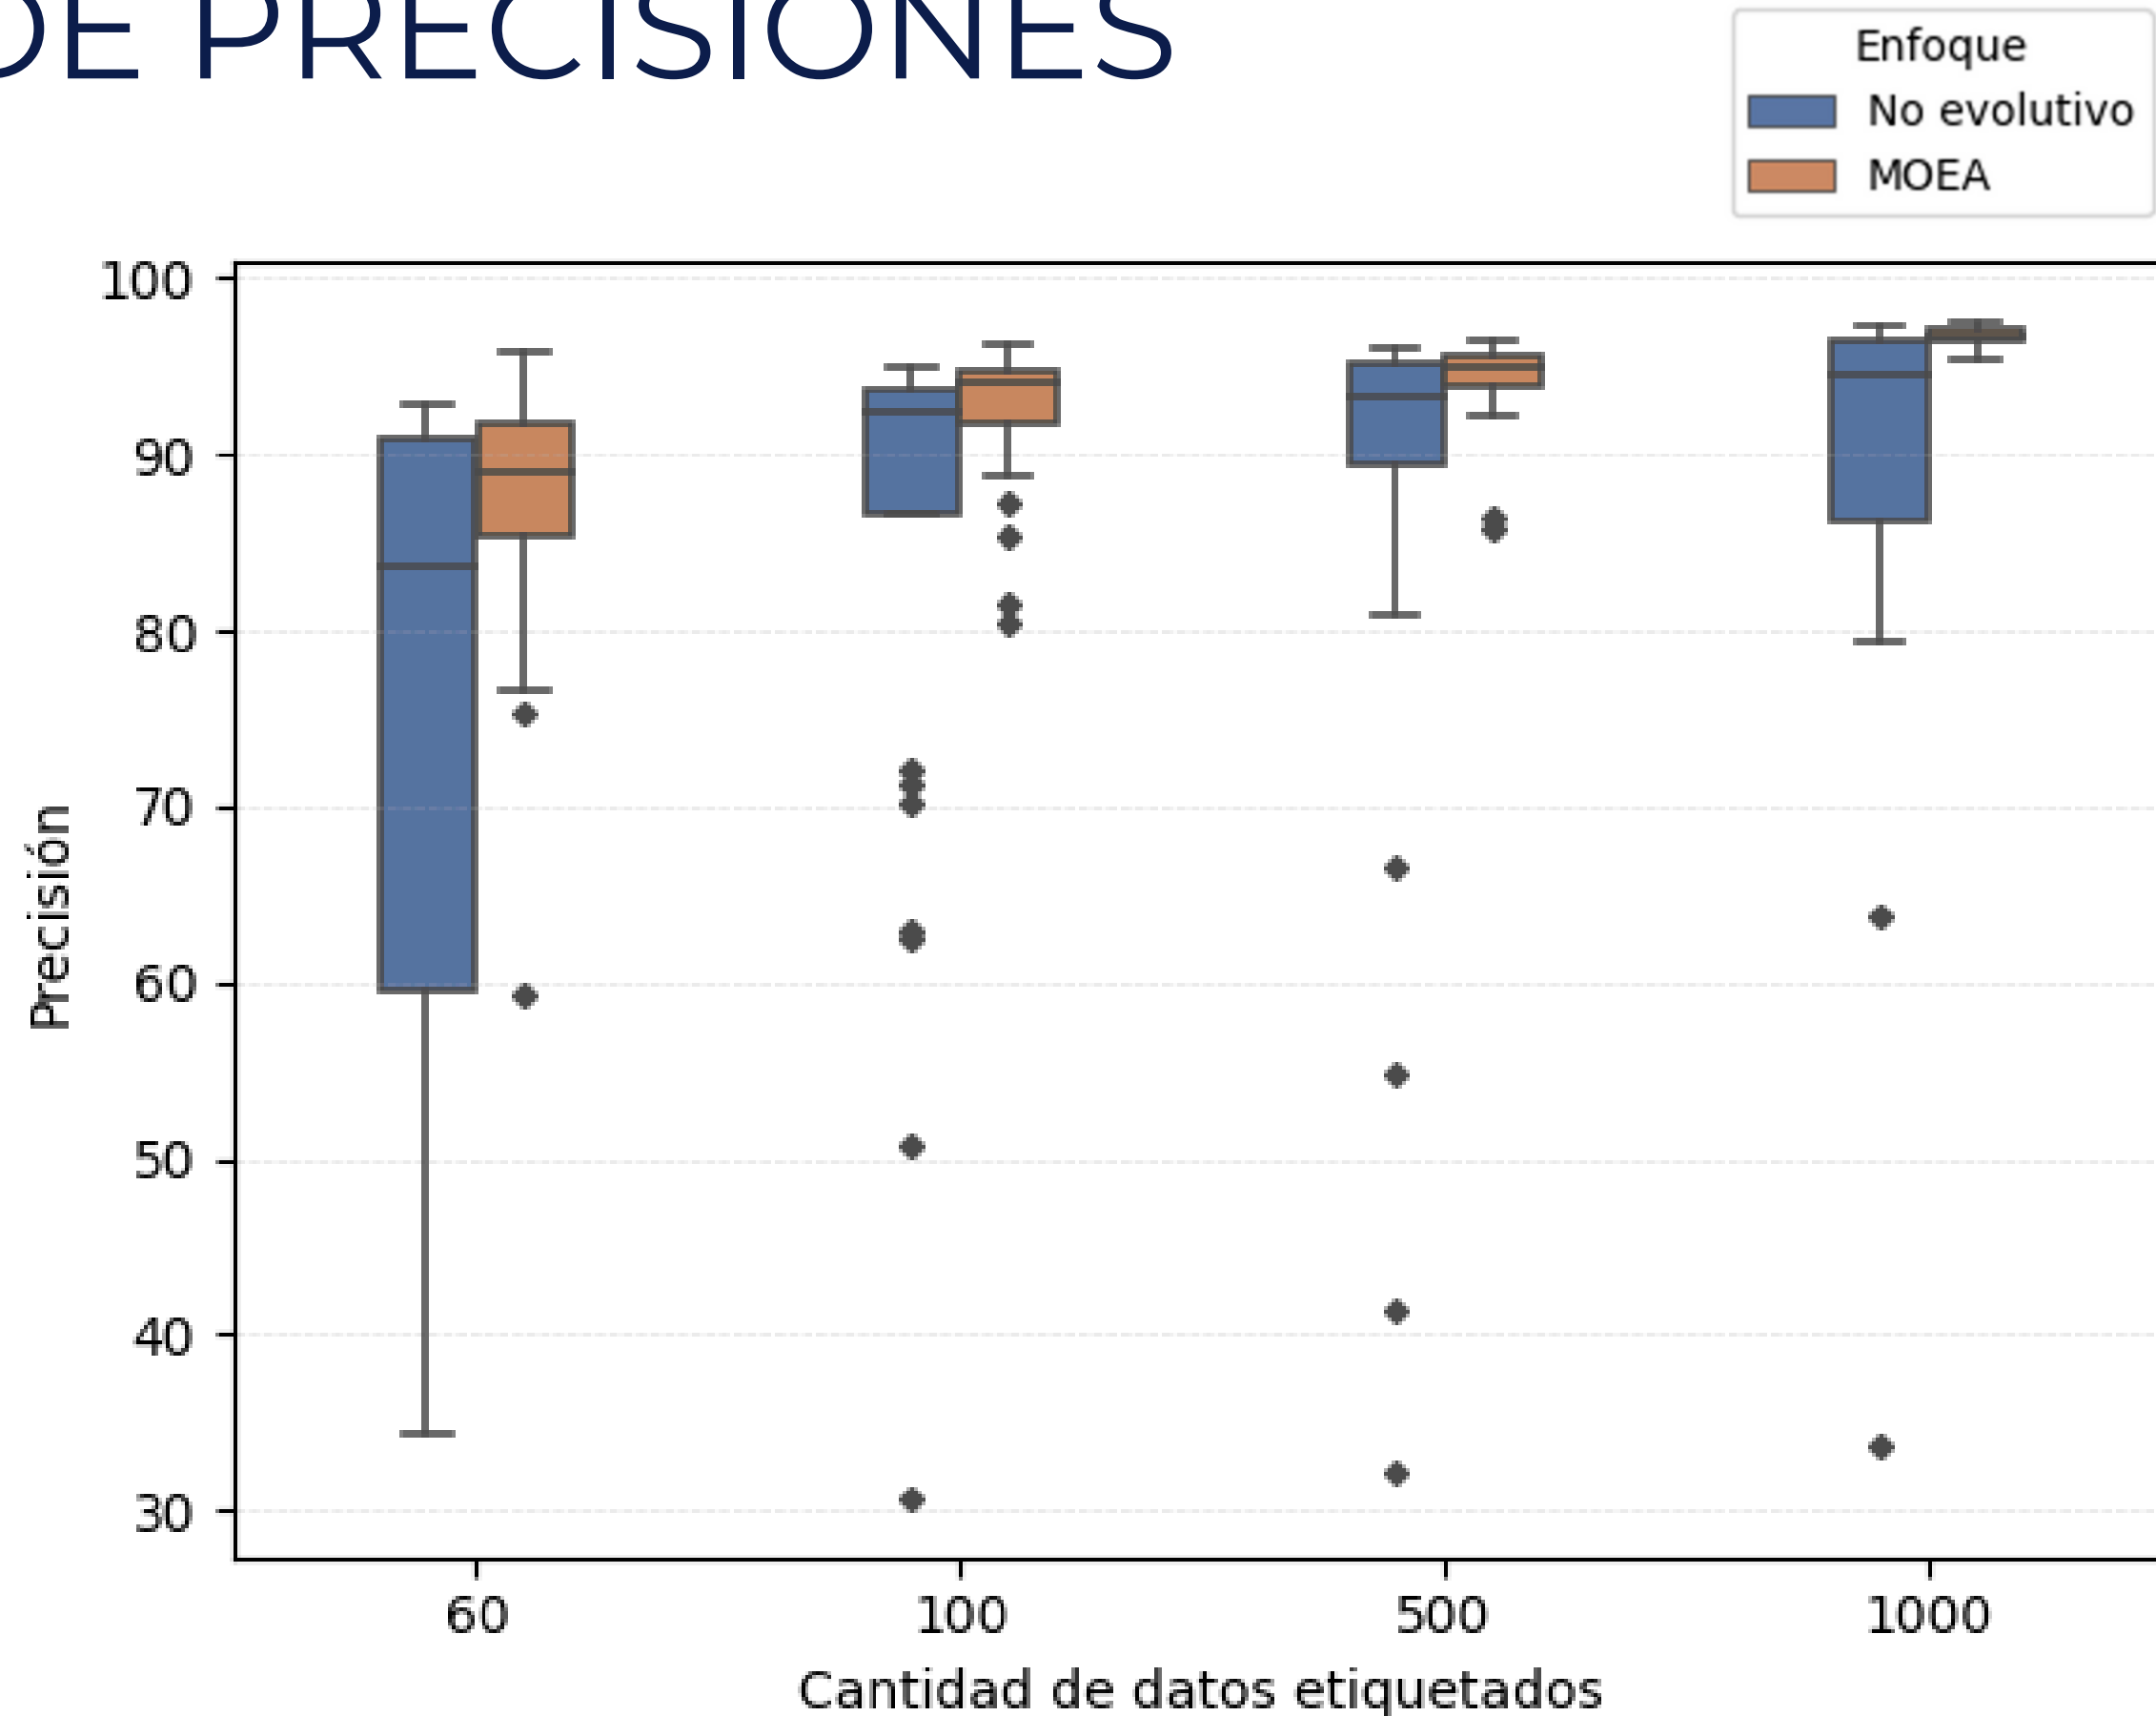


#Discriminadores	Cantidad de datos etiquetados			
	60	100	500	1000
1	79.54	86.50	92.13	-
2	87.68	92.19	90.21	95.84
3	90.27	94.05	94.81	96.54
4	92.67	94.73	95.31	96.89

COMPARACIÓN DE PRECISIONES

MOEA logró:

- desvíos 56%–97% menores.
- medias +10–12%.
- medianas hasta +5.43%.
- costo computacional x3.



CONCLUSIONES



1. Entrenamiento de GAN sin AE.



2. Hibridación con AE aporta robustez en el entrenamiento.



3. MOEA logra mejoras de precisión (valores cercanos al estado del arte).



4. FID estable.



¡Muchas
gracias!



...

Preguntas?

...