


IA FRUGAL: CUANDO MENOS ES MÁS



Amparo Alonso Betanzos



GOBIERNO
DE ESPAÑA

MINISTERIO
DE CIENCIA, INNOVACIÓN
Y UNIVERSIDADES


MINISTERIO
PARA LA TRANSFORMACIÓN DIGITAL
Y DE LA FUNCIÓN PÚBLICA

SECRETARÍA DE ESTADO
DE DIGITALIZACIÓN
E INTELIGENCIA ARTIFICIAL

red.es



AL PRINCIPIO.....



Sistemas diseñados por humanos que, dada una meta compleja, actúan en su entorno (físico o digital) **percibiendo** este entorno mediante la adquisición de datos, **interpretando** los datos estructurados o no estructurados recogidos, **razonando sobre el conocimiento** derivado de estos datos y **decidiendo** cuales serían las **mejores acciones** a realizar.



NUEVOS MODELOS DISRUPTIVOS

Redes profundas /Aprendizaje por refuerzo

Imita el aprendizaje humano

Recompensa si la acción es correcta

Penaliza si la acción es incorrecta





Figura 12.2 Arquitectura de red profunda con múltiples capas.




- Permite trabajar en entornos cambiantes y complejos
Se adapta continuamente de forma autónoma
Ajusta resultados
- Flexible
- Puede desarrollar estrategias cada vez más sofisticadas
- Reduce costes de desarrollo y mantenimiento de soluciones

El impacto del aprendizaje profundo en la inteligencia artificial



Facilita el uso de datos complejos (texto, imágenes...)
Permite resolver problemas más difíciles



LA IA GENERATIVA

4



• IA tradicional



La Inteligencia Artificial frugal

Modo IA Todo Imágenes Vídeos Noticias Productos Web Más Herramientas

Universidade da Coruña



Inteligencia Artificial Frugal: Aprendizaje Automático con ...

de P Fernández Pérez · 2024 — Se trata de una técnica que busca capacitar a los modelos para realizar tareas con un número limitado de ejemplos de entrenamiento y que proporciona soluciones ...

Universidade da Coruña

https://www.udc.es › ldiagroup › proyectos_id › frugalia

FrugallA

La IA Frugal permite: 1) mejorar la sostenibilidad del desarrollo y aplicación de la Inteligencia Artificial, 2) democratizar su uso reduciendo la demanda ...

DiarioBitcoin

https://www.diariobitcoin.com › startups-verticales › ia-...

IA frugal gana terreno frente al dominio de Big Tech y sus ...

3 abr 2026 — La carrera global por la inteligencia artificial suele medirse en centros de datos, chips de última generación y presupuestos de escala ...

Agenda Pública

https://agendapublica.es › noticia › ue-puede-ser-releva...

La UE puede ser relevante en IA mediante un desarrollo ...

20 feb 2025 — Entre ellos, destacan la posible destrucción masiva de empleos, la manipulación de la información y la amenaza para la democracia, o la ...

Asociación Almendrán

https://www.almendron.com › ... › 2025 › Marzo › 17

Por qué la IA frugal por sí sola no solucionará el problema ...

17 mar 2025 — En respuesta, las empresas tecnológicas promueven prácticas de IA frugales y apoyan la investigación centrada en la reducción del consumo de ...

Inteligencia Artificial Frugal

La IA que hace más con menos, priorizando la eficiencia, la accesibilidad y la sostenibilidad.

La **Inteligencia Artificial Frugal** es un paradigma que busca **desarrollar sistemas de IA potentes pero con recursos limitados**, optimizando el uso de datos, energía y capacidad computacional sin sacrificar el rendimiento. A diferencia de los modelos tradicionales — que dependen de grandes volúmenes de datos, infraestructuras costosas y alto consumo energético—, la IA frugal se centra en:

1. Eficiencia computacional:

- Modelos **ligeros y optimizados** (ej. *distilled models*, *quantized neural networks*) que funcionan en hardware accesible (incluso en dispositivos *edge* como móviles o sensores).
- Ejemplo: Modelos como **MobileNet** o **TinyML** permiten ejecutar IA en dispositivos con recursos limitados.

2. Sostenibilidad:

- Reducción del **consumo energético** (la IA tradicional puede emitir tanto CO₂ como **5 coches a lo largo de su vida útil**).
- Uso de **energías renovables** y algoritmos diseñados para minimizar la huella de carbono (ej. *Green AI*).

3. Accesibilidad y autonomía:

- Democratización de la IA:** Permite que pequeñas empresas, países en desarrollo o instituciones públicas implementen soluciones de IA sin depender de grandes corporaciones (EE.UU./China).
- Soberanía tecnológica:** Reduce la dependencia de infraestructuras extranjeras (ej. ...)

+ Escribe / para acceso rápido

Reflexionar



LA IA AGÉNTICA

5



Cambio de paradigma:

de RESPONDER a ACTUAR



Nueva evolución, sistemas que interactúan proactivamente con el entorno

Opera de forma autónoma para alcanzar un objetivo complejo, sin intervención humana:

- Puede percibir el entorno
- Razonar e interpretar
- Decidir y ejecutar de forma autónoma



IA RESPONSABLE

Tecnología al servicio de las personas y del planeta



IA CENTRADA EN LAS PERSONAS

Number of reported AI incidents, 2012–25

Source: AI Incident Database (AIID), 2025 | Chart: 2026 AI Index report





Figure 3.2.1²

REGULACIÓN EN LA UE

2019



2024

2021

Ley de Inteligencia Artificial de la UE: Niveles de riesgo



2023



Es prioridad del Parlamento asegurarse de que los sistemas de IA que se usen en la UE son seguros, transparentes, trazables, no discriminatorios y **respetuosos con el medioambiente**

2024



Artículo 28b(2)(d): Se requiere que los proveedores de modelos base se adhieran a estándares para **reducir el uso de energía y recursos**, **mejorar la eficiencia energética** y habilitar la **medición y el registro del impacto ambiental**.

COMPLEJIDAD, PROFUNDIDAD y PARÁMETROS


Deep and steep

Computing power used in training AI systems

Days spent calculating at one petaflop per second*, log scale


By fundamentals

Language Speech Vision
Games Other




Source: OpenAI
The Economist

15,000x increase in 5 years



¿PRECISIÓN?



ATERRIZANDO CIFRAS

Entrenamiento:

- 1.300.000kWh
- 552 ton. CO2
- 700.000 l. agua



Consumo anual energía de 126 casas en Dinamarca

700.000 km

Accesos Enero 2023:

- 590 millones



Consumo de electricidad de 175.000 personas

Estimated carbon emissions from training select AI models and real-life activities, 2012–25

Source: AI Index, 2026; Strubell et al., 2019 | Chart: 2026 AI Index report




Figure 1.4.3

CONTAMINACIÓN Y PARÁMETROS

Estimated carbon emissions and number of parameters by select AI models

Source: AI Index, 2026 | Chart: 2026 AI Index report


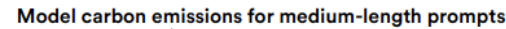




Figure 1.4.4


USAR IA GENERATIVA TAMBIÉN CONTAMINA



Source: Jegham et al., 2025 | Chart: 2026 AI Index report


Figure 1.4.6¹⁴

CONSUMO DE AGUA



Annual water consumption: GPT-4o vs. real-world baselines

Source: AI Index, 2025 | Chart: 2026 AI Index report



EL COSTE ECONÓMICO

Hardware and energy cost to train notable AI systems


This data is expressed in US dollars, adjusted for inflation.

Table Scatter



Settings

Cost (constant 2023 US\$; plotted on a logarithmic axis)



Dec 2, 2015 Apr 5, 2025

Data source: Epoch AI (2025) – [Learn more about this data](#)

Note: This data is expressed in constant 2023 US\$. The hardware costs are amortized and calculated by multiplying the training chip-hours by the reduced hardware cost, with an additional 23% for networking expenses. The costs of some models vary in certainty, as some use actual price data rather than estimates.

OurWorldinData.org/artificial-intelligence | CC BY

SELECT COUNTRIES AND REGIONS

Search for a country or region

Sort by: Hardware and energy c... ↓

All countries and regions

☐	Grok-3	\$305.01M
☐	GPT-4.5	\$187.87M
☐	Llama 3.1-405B	\$52.88M
☐	Llama 4 Behemoth (preview)	\$44.59M
☐	GPT-4	\$42.17M
☐	GPT-4o	\$37.43M
☐	GLM-4-Plus	\$32.71M
☐	Grok-2	\$31.6M
☐	Gemini 1.0 Ultra	\$29.33M
☐	Claude 3.5 Sonnet	\$25.87M
☐	GPT-4 Turbo	\$25.39M
☐	Nemotron-4 340B	\$21.27M
☐	Claude 3 Opus	\$17.11M
☐	Mistral Large	\$14.62M


LAS CONSECUENCIAS GEOPOLITICAS

THE RISING COSTS OF TRAINING FRONTIER AI MODELS


Ben Cottier¹ Robi Rahaman^{1,2}
Loredana Fattorini² Nestor Maslej² Tamay Beiroghli¹ David Owen¹

arXiv:2405.21015v2 [cs.CY] 7 Feb 2025

Amortized hardware, energy, and R&D staff costs for training and experiments



Percentage of costs for training and experiments of ML models



Notable AI models (% of total) by sector, 2003–24

Source: Epoch AI, 2025 | Chart: 2025 AI Index report





Figure 1.3.5

Number of notable AI models by select geographic areas, 2003–24

Source: Epoch AI, 2025 | Chart: 2025 AI Index report



DEL ROJO AL VERDE


- Progreso de la IA marcado por el **uso masivo de datos** y la **disponibilidad de hardware potente**.
- Los **recursos humanos son enormes**, en personal de diferentes tipos, etiquetado, pruebas, etc.
- Los **recursos económicos** necesarios son **ingentes**
- Los modelos han sido posibles gracias a **enormes cantidades de datos, parámetros y energía**.



Modelo no sostenible, ni económico, ni ecológico, ni social

Soberanía tecnológica

Democracia



Enorme sobrecarga informática

Rendimiento como único objetivo

IA
ROJA

Tener en cuenta las repercusiones
medioambientales, sociales y
económicas de la IA

Asesoramiento multidimensional
balanceado

IA
VERDE

INTELIGENCIA ARTIFICIAL FRUGAL

IA Frugal


- IA diseñada para operar de forma eficiente en contextos con limitación de recursos

PRINCIPIOS

- Eficiencia de recursos
- Bajo coste
- Simplicidad
- Sostenibilidad
- Democratización de acceso



LO QUE NO SE MIDE, NO SE PUEDE MEJORAR



<https://mlco2.github.io/impact/>

Publicada la Especificación UNE 0086:2025 sobre medición del consumo energético, huella de carbono, consumo del agua y rendimiento de sistemas de Inteligencia Artificial

Mié, 12/11/2025 - 12:31 ● IA SOSTENIBLE



Compartir: [f](#) [x](#) [in](#)

La Asociación Española de Normalización (UNE) ha publicado la nueva Especificación UNE 0086:2025, un documento pionero que establece el marco de referencia para la medición del consumo energético, la huella de carbono, el consumo del agua y el rendimiento de los sistemas de Inteligencia Artificial (IA).

EL PNAV LANZA UNA CALCULADORA PARA MEDIR EL CONSUMO ENERGÉTICO DE PROGRAMAS INFORMÁTICOS DE IA

Mar, 07/10/2025 - 12:46 ● GREEN TECH

El Programa Nacional de Algoritmos verdes ha desarrollado una herramienta para medir el consumo energético de programas informáticos de IA y servir como punto de partida para alinearse con los criterios definidos en la especificación UNE 0086 para concienciar sobre el impacto en la huella de carbono del uso de softwares



ESTRATEGIAS



DATOS

Eficiencia informativa
IA centrada en los datos



APRENDIZAJE

Eficiencia computacional
IA centrada en el modelo



INFERENCIA

Eficiencia práctica



DATOS


OBJETIVO:

- Reducir costes: adquisición, almacenamiento y explotación
- Mejorar la calidad

Restricciones de recursos, privacidad, transparencia

¿QUÉ PODEMOS HACER?

Influencia del tamaño del conjunto de datos



Usar menos datos o características
Conjuntos más pequeños y de más calidad

¿CÓMO?

- Reducción de dimensionalidad
- Aprendizaje positivo sin etiquetas
(Positive Unlabelled Learning)
- Aprendizaje Activo
(Active Learning)
- Aprendizaje con pocos casos
(Few-shot Learning)

REDUCCIÓN DE DIMENSIONALIDAD.

Métricas de complejidad





Fig. 4. Comparing the centralized and distributed approaches using horizontal partition in terms of classification accuracy.

Table 6

Maximum runtime (s) for the feature selection methods tested. C stands for centralized approaches, while D refers to the distributed approaches.

		Connect4	Isolet	Madelon	Ozone	Spambase	Mnist	SpeedUp
CFS	C	100	250	36	10	12	1787	5.73
	D	10	77	25	8	6	257	
INT	C	112	196	40	9	13	3145	10.56
	D	11	70	31	8	14	199	
Cons	C	268	245	52	11	14	6163	21.10
	D	10	80	25	6	2	197	
IG	C	97	171	41	9	11	1451	5.30
	D	4	54	29	9	5	235	
ReliefF	C	1680	553	62	14	21	30,413	21.66
	D	11	103	40	8	4	1346	

REDUCCIÓN DE DIMENSIONALIDAD.



Modelos precisión reducida




Feature selection with limited bit depth mutual information for portable embedded systems

Laura Morán-Fernández^{a,*}, Konstantinos Sechidis^b, Verónica Bolón-Canedo^a, Amparo Alonso-Betanzos^a, Gavin Brown^b


^aOTIC, Universidade da Coruña, A Coruña, Spain
^bSchool of Computer Science, University of Manchester, Manchester, UK



Punto fijo algoritmos basados en Información Mutua



(a) 5-top features



(c) 20-top features

3-NN


5-fold validación cruzada

Test Friedman test con Nemenyi post-hoc test


APRENDIZAJE POSITIVO SIN ETIQUETAS (PU Learning)

Explicaciones visuales con contenido pre-existente

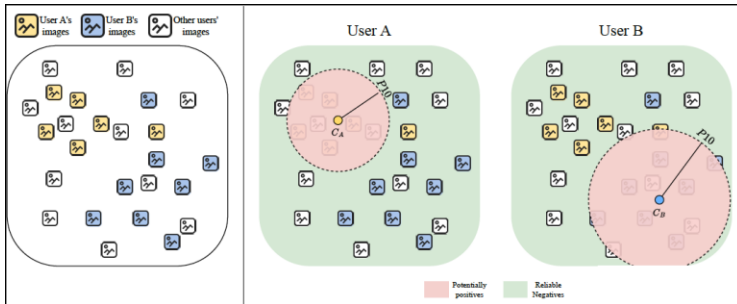

Aprendizaje



Explicación




APRENDIZAJE POSITIVO SIN ETIQUETAS



City	Train Partition			Test Partition		
	Users	Restaurants	Images	Users	Restaurants	Images
Gijón	5,139	598	16,302	1,023	346	2,377
Barcelona	33,537	5,881	130,674	8,697	3,211	19,742
Madrid	43,628	6,810	176,763	11,874	3,643	27,142
New York	61,019	7,588	196,315	16,842	4,135	34,826
Paris	61,391	11,982	219,588	15,242	6,345	32,048
London	134,816	13,888	416,356	30,393	8,097	63,442

Mejora en media sobre Estado del Arte (ELVis)




MEJORANDO PRIORIZACIÓN GENÉTICA CON Aprendizaje PU

⚠ **Asunción:** Para entrenar un clasificador binario, se asume que los genes sin relación DR (restricción dietaria) conocida son ejemplos negativos


Asumir genes no etiquetados como ejemplos negativos

Aprender con datos con ruido (muchos falsos negativos)

Peor predicción de genes candidatos



Method	Features	Classifier	Performance (avg of 10 runs)		
			AUC-ROC	G. Mean	F1 Score
Original	PathDIP	CAT	0.829	0.717	0.522
		BRF	0.825	0.752	0.450
	GO	CAT	0.832	0.654	0.463
		BRF	0.827	0.755	0.377
PU Learning	PathDIP	CAT	0.829	0.750	0.537†
		BRF	0.815	0.728	0.381
	GO	CAT	0.838†	0.726	0.491
		BRF	0.829	0.763†	0.380



Original non-PU-Learning method		KNN-based PU-Learning method	
Gene	DR-Probability	Gene	DR-Probability
GOT2	0.86	<i>TSC1</i>	0.97
GOT1	0.85	<i>GCLM</i>	0.94
<i>TSC1</i>	0.85	IRS1	0.93
CTH	0.85	PRKAB1	0.92
<i>GCLM</i>	0.82	PRKAB2	0.90
<i>IRS2</i>	0.80	PRKAG1	0.90
SENS2	0.80	<i>IRS2</i>	0.90

- Los genes propuestos por PU son:
 - Más fiables
 - Mayor soporte en la literatura científica
-  GenDR anota IRS1 e IRS2 como genes relacionados con DR.

OBJETIVOS:

Desarrollar modelos de aprendizaje más eficientes y sostenibles

OTRAS NECESIDADES ABORDADAS:

Restricciones de recursos, privacidad, sesgos, opacidad

¿QUÉ PODEMOS HACER?

Usar modelos más ligeros, con menos necesidades de hardware y parámetros

¿CÓMO?

- Aprendizaje por transferencia
- Modelos verdes y modelos en baja precisión
- Aprendizaje en el borde/federado (Edge/Federated computing)
- Aprendizaje continuo (Long-life Learning)
- Aprendizaje modular



APRENDIZAJE

Búsqueda arquitectura
modelo

Entrenamiento modelo

Inferencia

BRIE: (Bayesian Ranking of Images for Explainability)



- **Hiper-personalización**

- Modelos obligados a procesar e interpretar millones de datos individuales.

- **Complejidad Epistémica**

- Crecimiento desmedido de parámetros que deriva en cajas negras opacas.

- **Sostenibilidad**


Model	RMSE (Performance)	gCO2 (Emissions)
Random	1,707	N/A
Naive (Dyad Average)	0,958	N/A
MF	0,840	56,449
GC-MC	0,846	243,349
Bayesian SVD++	0,830	358,900
Glocal-K	0,826	2038,492

Ganancias de rendimiento marginales,
incrementos exponenciales en eCO₂ en el entrenamiento




- **Equidad y Justicia**

- **Métricas**

- Evaluaciones basadas únicamente en rendimiento técnico (RMSE/MAE).



RENDIMIENTO, EXPLICABILIDAD Y SOSTENIBILIDAD: Modelos ligeros



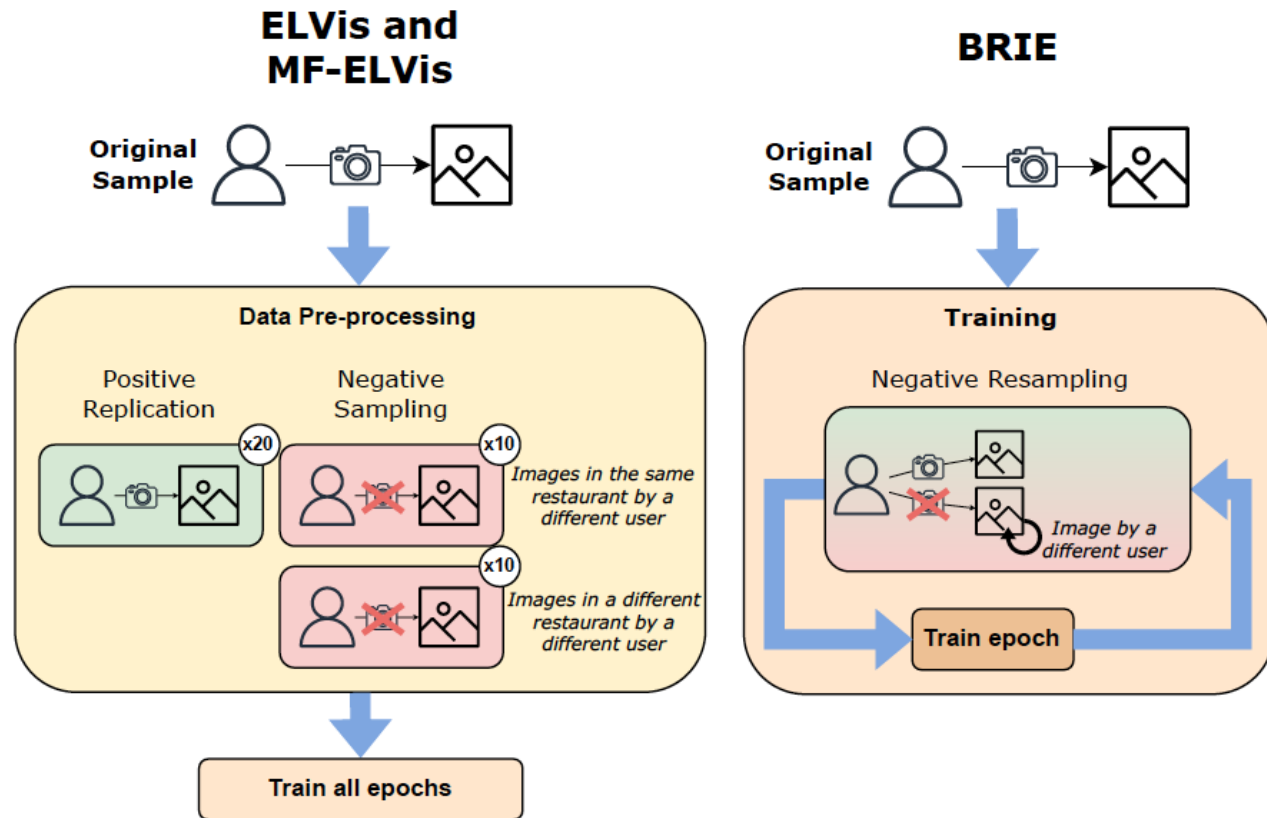
Explicabilidad visual a través de imágenes proporcionadas por los propios usuarios de la plataforma

No requiere generación

Son autocontenidas

No requiere información explícita del usuario

MODELO MÁS FRUGAL



Etiquetado dinámico pares

- Las muestras se regeneran en cada epoch
- No se requiere el almacenamiento de las muestras
- No se requiere aumentar el tamaño del conjunto de entrenamiento

MÁS FRUGALES Y TAMBIÉN MÁS PRECISOS




	Gijón			Barcelona			Madrid		
	MRecall@10	MNDCG@10	MAUC	MRecall@10	MNDCG@10	MAUC	MRecall@10	MNDCG@10	MAUC
RND	0.373	0.185	0.487	0.409	0.186	0.502	0.374	0.171	0.499
CNT	0.464	0.218	0.546	0.443	0.219	0.554	0.420	0.203	0.557
ELVis	0.521	0.262	<u>0.596</u>	<u>0.597</u>	<u>0.327</u>	<u>0.631</u>	<u>0.572</u>	<u>0.314</u>	<u>0.638</u>
MF-ELVis	<u>0.538</u>	<u>0.285</u>	0.592	0.557	0.293	0.596	0.528	0.279	0.601
BRIE	0.607	0.333	0.643	0.630	0.368	0.663	0.612	0.348	0.673

	Newyork			Paris			London		
	MRecall@10	MNDCG@10	MAUC	MRecall@10	MNDCG@10	MAUC	MRecall@10	MNDCG@10	MAUC
RND	0.374	0.168	0.502	0.459	0.209	0.502	0.342	0.155	0.500
CNT	0.431	0.217	0.563	0.499	0.245	0.557	0.400	0.200	0.562
ELVis	<u>0.553</u>	<u>0.304</u>	<u>0.637</u>	<u>0.643</u>	<u>0.352</u>	<u>0.630</u>	0.530	<u>0.293</u>	<u>0.629</u>
MF-ELVis	0.516	0.276	0.602	0.606	0.323	0.596	<u>0.531</u>	0.267	0.597
BRIE	0.598	0.341	0.677	0.669	0.391	0.666	0.563	0.318	0.665




ENTRENAMIENTO Y USO

Tiempo de entrenamiento vs AUC test




Emisiones CO2 vs AUC test



MEDIR ES IMPORTANTE: EAUC

Datos diádicos donde las interacciones se definen mediante salidas numéricas




IEEE TRANSACTIONS ON NEURAL NETWORKS AND LEARNING SYSTEMS, VOL. 36, NO. 11, NOVEMBER 2025

19619

Beyond RMSE and MAE: Introducing EAUC to Unmask Hidden Bias and Unfairness in Dyadic Regression Models

Jorge Paz-Ruza¹, Amparo Alonso-Betanzos², Bertha Guijarro-Berdiñas³, Brais Cancela⁴, and Carlos Eiras-Franco⁵



- Métricas comunes
 - RMSE
 - MAE
 - etc.
- El error global es una métrica aceptable para la regresión clásica
 - Pero los datos diádicos son complejos y dispersos
- MAE y RMSE suelen enmascarar sesgos



PROPUESTA: MEDIDA DE EXCENTRICIDAD

Valoración media de usuarios/items

$$\bar{r}_u = \frac{1}{|\mathcal{I}_u|} \sum_{i \in \mathcal{I}_u} r_{ui} \quad \bar{r}_i = \frac{1}{|\mathcal{U}_i|} \sum_{u \in \mathcal{U}_i} r_{ui}$$



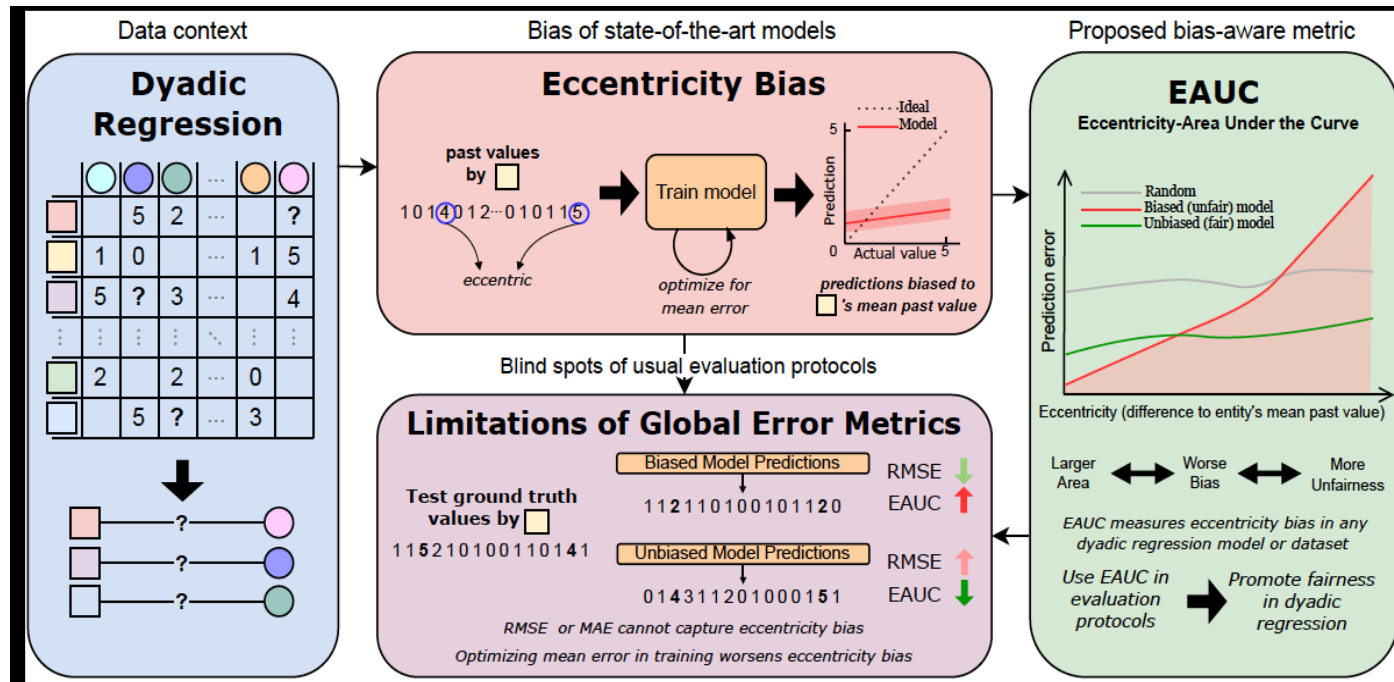
Valor medio diádico (valor esperado) del par usuario-item

$$DMV_{ui} = \frac{\bar{r}_u + \bar{r}_i}{2}$$

Excentricidad (Eccentricity) (valor inesperado) de una valoración

$$Ecc_{ui} = |r_{ui} - DMV_{ui}|$$

USO DE LA MÉTRICA



NECESIDAD DE MÉTRICAS Y METODOLOGÍAS

a) Melanoma Detection

Expert requirements


 >0.95 AUC-ROC

 >85% ISO 22857:2013
data protection compliance

Performance > Sustainability

 $\leq 0.01 \Delta(\text{EO})$ (Light/Dark Skin)

 >4 Human Interpretability (1-5)



— Model A
— Model B
— Min Reqs

➔ **A** ☒
B ☒

IA FRUGAL: DECISIÓN ESTRATÉGICA Y ÉTICA



REDUCIR IMPACTO
AMBIENTAL

DEMOCRATIZACIÓN
DE LA IA

TRABAJAR EN
ENTORNOS CON
RESTRICCIONES

DIMENSIÓN SOCIAL:
CONFIANZA
(SESGOS,
EXPLICABILIDAD)

SOBERANÍA
TECNOLÓGICA



GRACIAS POR SU ATENCIÓN

Amparo Alonso Betanzos
amparo.alonso.betanzos@udc.es

