

Análisis de sostenibilidad de Sistemas de Recomendación

Xesús Patiño¹, Jorge Paz-Ruza¹, Bertha Guijarro-Berdiñas¹, and Amparo Alonso-Betanzos¹

Universidade da Coruña, CITIC, Campus de Elviña s/n 15071, A Coruña x.patinom, j.ruza, berta.guijarro, amparo.alonso.betanzos@udc.es

Abstract

Los Sistemas de Recomendación (RS) son herramientas esenciales que mejoran la experiencia de usuario, aunque su entrenamiento puede consumir muchos recursos, generando un alto impacto ambiental. Este trabajo presenta una metodología novedosa para evaluar su sostenibilidad, analizando el equilibrio entre el rendimiento y el coste computacional en los casos de uso de entrenamiento e inferencia más representativos de usos reales de los RS. Este trabajo compara combinaciones de modelos, métodos y conjuntos de datos, utilizando métricas de sostenibilidad. Los resultados demuestran que esta metodología es útil para identificar, dentro de un conjunto de modelos, las configuraciones que logran el mejor equilibrio entre rendimiento y sostenibilidad, sirviendo así como una guía para crear Sistemas de Recomendación más ecológicos.

1 Introduction

Los Sistemas de Recomendación (RS), que de forma genérica buscan emparejar usuarios e ítems, son fundamentales en el consumo digital, pero acarrean un entrenamiento muy intensivo que ignora el alto coste computacional y ambiental [1]; esto plantea un desafío en el ámbito de la IA Verde. Este trabajo abarca tres objetivos: 1) analizar la sostenibilidad de diferentes RS, 2) proponer nuevas metodologías de evaluación realistas que integren la precisión con la sostenibilidad, y 3) identificar paradigmas que logren un equilibrio entre rendimiento y sostenibilidad.

2 Métodos

Para la propuesta metodológica se analizaron 8 modelos de recomendación, clasificados en tres arquitecturas principales: Factorización de Matrices (MF, NMF), Redes Neuronales Profundas (AutoRec, NCF, LRML) y Redes Neuronales de Grafos (LGCN, GHRN, KGNN-LS). Para asegurar la robustez, se emplearon seis conjuntos de datos en áreas como la economía, la farmacología o la recomendación de productos. Utilizando la herramienta CodeCarbon, se llevó a cabo la evaluación de tres procesos de entrenamiento e inferencia como vemos en la Figura 1: punto a punto; basada en historial; y predicción de Top-k.



Figure 1: Procesos de entrenamiento e inferencia

3 Resultados

Los resultados de la Figura 2 demuestran que el equilibrio entre eficiencia y sostenibilidad depende mucho del entrenamiento e inferencia. En el enfoque **punto a punto**, se identificó un claro punto de equilibrio donde los modelos clásicos (MF, LRML) tienen resultados competentes en precisión con arquitecturas más complejas, pero con una huella de carbono inferior. Sin embargo, en la metodología **basada en el historial**, el alto coste del entrenamiento penalizó a los modelos anteriores, siendo otras arquitecturas (NCF, NNMF) opciones más equilibradas. Finalmente, en la **predicción Top-K**, se confirmó que modelos como MF y GHRs son excelentes para encontrar ítems relevantes. Igualmente, otros modelos (LRML) son válidos según se priorice la recuperación de ítems relevantes (Recall) o la precisión del orden de estos (NDCG). Estos resultados reafirman la necesidad de que la selección del modelo dependa del contexto y esté guiada por la métrica de sostenibilidad.

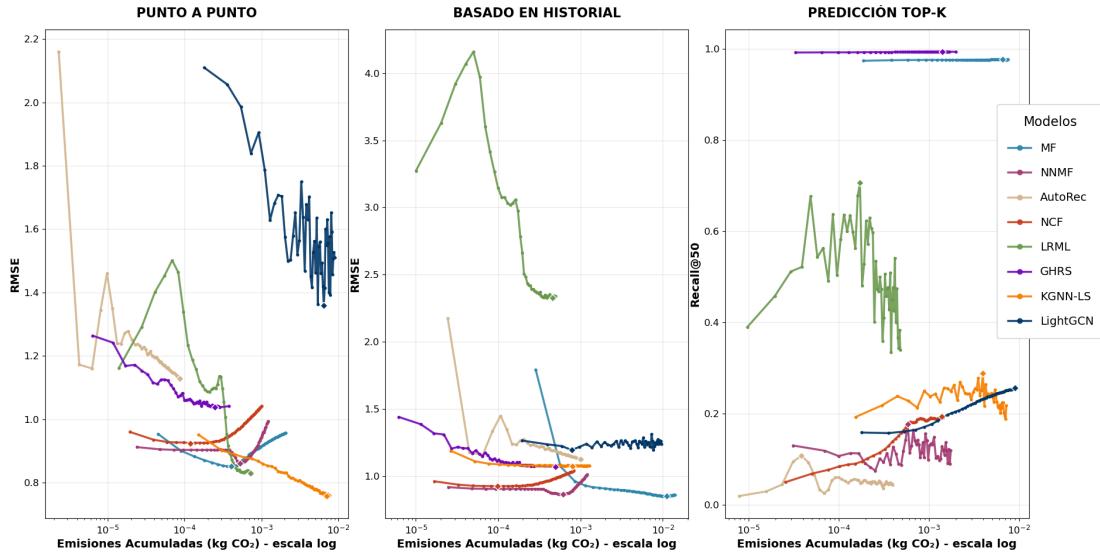


Figure 2: Relación entre rendimiento y emisiones acumuladas (escala logarítmica) de los procesos de entrenamiento e inferencia para cada modelo.

4 Conclusión

Este trabajo propone nuevas metodologías realistas de evaluación de sostenibilidad para RS, variando la bondad de los modelos en función de la metodología utilizada. En consecuencia, demostramos la necesidad de una selección y un desarrollo inteligentes del RS en función del contexto y la sostenibilidad como criterios clave.

References

- [1] Giuseppe Spillo, Allegra De Filippo, Cataldo Musto, Michela Milano, and Giovanni Semeraro. Towards sustainability-aware recommender systems: Analyzing the trade-off between algorithms performance and carbon footprint. pages 856–862, 2023. Accessed: 2025-05-27.