

Computación distribuida sostenible: hibridando optimización metaheurística y bayesiana

Mariano Garralda-Barrio, Carlos Eiras-Franco, and Verónica Bolón-Canedo

Universidade da Coruña (UDC), CITIC, A Coruña, España
`mariano.garralda@udc.es`

Resumen

El crecimiento del cómputo distribuido y la inteligencia artificial plantea un reto urgente de sostenibilidad energética. Los sistemas actuales ejecutan grandes volúmenes de tareas cuyo coste depende de la eficiencia de sus configuraciones y del uso de recursos. Este trabajo presenta una línea de investigación orientada a desarrollar un marco de optimización continua que equilibre rendimiento y consumo energético mediante transferencia segura de conocimiento, metaheurísticas y optimización bayesiana. Se sintetizan la motivación, el planteamiento conceptual y los resultados iniciales que orientan esta iniciativa hacia una computación más sostenible.

1. Motivación

La expansión de los sistemas de inteligencia artificial y de procesamiento distribuido ha incrementado su impacto energético. Infraestructuras de cómputo masivo, como Apache Spark [1], ejecutan grandes volúmenes de tareas con un coste proporcional al tamaño de los datos y a la eficiencia de sus configuraciones. La búsqueda de una *IA verde* [2] exige mecanismos capaces de adaptar estos sistemas de forma autónoma y sostenible, optimizando recursos y aprovechando conocimiento previo para evitar evaluaciones redundantes.

2. Planteamiento del problema

La configuración de aplicaciones distribuidas involucra numerosos parámetros interdependientes (paralelismo, particionado, memoria, etc.), que generan un espacio de búsqueda complejo, no lineal y con múltiples óptimos locales. Una exploración manual o exhaustiva del espacio de soluciones en busca de configuraciones óptimas resulta ineficiente e inviable. Además, la variabilidad de cargas y escalas de entrada requiere una optimización continua y energéticamente consciente, capaz de aprender de ejecuciones previas mediante transferencia segura de conocimiento.

3. Objetivo y propuesta conceptual

El objetivo es diseñar un sistema de optimización continua en Spark, basado en un bi-criterio (T_R) que minimice el producto geométrico ponderado del tiempo de ejecución y los recursos hardware utilizados:

$$T_R = T^\beta R^{1-\beta}, \quad (1)$$

donde T es el tiempo de ejecución y R la agregación de recursos físicos (CPU y memoria). El parámetro β permite ajustar la prioridad entre rendimiento y eficiencia según el contexto. Nuestra propuesta combina tres módulos interdependientes:

- **Transferencia segura de conocimiento:** reutilización de ejecuciones previas mediante descriptores de carga y criterios de similitud [3, 4];
- **Metaheurísticas adaptativas:** exploración local guiada por estabilidad y diversificación segura mediante Iterated Local Search–Tabu Search [5];
- **Optimización bayesiana:** selección inteligente de configuraciones bajo presupuestos limitados de evaluación [6].

El sistema se actualiza de forma incremental, integrándose en los ciclos periódicos de ejecución y promoviendo configuraciones más eficientes y sostenibles.

4. Resultados experimentales

Las pruebas sobre cargas heterogéneas y distintos volúmenes de datos mostraron mejoras consistentes respecto a los enfoques convencionales. El método híbrido alcanzó convergencias más estables y rápidas, reduciendo reevaluaciones costosas. En conjunto, se observaron descensos simultáneos del tiempo de ejecución y del uso de recursos, traducándose en menor energía estimada sin pérdida de rendimiento.

5. Conclusión

Esta iniciativa aplica los principios de la IA verde a la optimización automática de parámetros en sistemas distribuidos. El marco híbrido propuesto equilibra rendimiento y sostenibilidad mediante aprendizaje por transferencia seguro y optimización metaheurística–bayesiana de bajo coste computacional. Los próximos pasos se orientan a validar su impacto energético en entornos reales de cómputo masivo, con el apoyo del Laboratorio de Innovación Aplicada (LIA) de Minsait (Indra Company), avanzando hacia infraestructuras de computación más sostenibles.

Referencias

- [1] Matei Zaharia, Mosharaf Chowdhury, Tathagata Das, Ankur Dave, Justin Ma, Murphy McCauley, Michael J. Franklin, Scott Shenker, and Ion Stoica. Apache Spark: A unified engine for big data processing. *Communications of the ACM*, 59(11):56–65, 2016.
- [2] Verónica Bolón-Canedo, Laura Morán-Fernández, Brais Cancela, and Amparo Alonso-Betanzos. A review of green artificial intelligence: Towards a more sustainable future. *Neurocomputing*, 599:128096, 2024.
- [3] Mariano Garralda-Barrio, Carlos Eiras-Franco, and Verónica Bolón-Canedo. A novel framework for generic spark workload characterization and similar pattern recognition using machine learning. *Journal of Parallel and Distributed Computing*, 189:104881, 2024.
- [4] Mariano Garralda-Barrio, Carlos Eiras-Franco, and Verónica Bolón-Canedo. Adaptive incremental transfer learning for efficient performance modeling of big data workloads. *Future Generation Computer Systems*, 166:107730, 2025.
- [5] Ilhem Boussaïd, Julien Lepagnot, and Patrick Siarry. A survey on optimization metaheuristics. *Information Sciences*, 237:82–117, 2013. Prediction, Control and Diagnosis using Advanced Neural Computations.
- [6] Y. et al. Gao. Bayesian optimization with local search. In *Machine Learning, Optimization, and Data Science*, pages 350–361. Springer, 2020.