Propuesta de TFM: **Física estadística de sistemas desordenados en *machine learning***

Aurélien Decelle y Beatriz Seoane Bartolomé (Dpto. Física Teórica, UCM)

Curso 2021/22

Técnicas de aprendizaje automatizado de datos, como el *deep learning* [4], han revolucionado en muy pocos años el reconocimiento de imágenes y sonido en Ingeniería, o de motivos en Genómica, y también abierto una multitud de nuevas oportunidades en ciencia incluida la Física. Pese a su evidente éxito práctico, la comprensión teórica de estas herramientas va muy por detrás de su uso, y preguntas tan cruciales como por qué aprenden estas redes neuronales o bajo qué condiciones específicas pueden hacerlo quedan aún por responder. La física estadística, y en concreto, la física de sistemas desordenados, tienen una larga tradición estudiando este tipo de problemas dada la proximidad entre los modelos de redes neuronales usados en inteligencia artificial y los modelos de física de vidrios[3]. Esta conexión (entre física y ciencias de computación) se ha visto propulsada en los últimos 5 años por el creciente interés en este tipo de tecnologías [5, 1].

En este TFM estudiaremos la física, y en particular, las propiedades dinámicas de equilibrio y de no equilibrio de diversos modelos de redes generativas, con un particular interés en las llamadas *Restricted Boltzmann Machines* [2]. Este método de aprendizaje no supervisado es conocido por su capacidad para generar nuevas muestras de datos similares a las usadas durante su entrenamiento, pero también tiene la enorme ventaja de ser capaz de aprender y extraer un Hamiltoniano de espines efectivo y una densidad de probabilidad que describe el conjunto de datos. Estos observables permiten algo raro en machine learning: interpretar y estudiar los patrones aprendidos por la máquina en un contexto científico más allá de la pura clasificación o generación de datos.

Los/as interesados/as en este TFM deben tener un fuerte interés por las temáticas de física estadística, sistemas complejos y física computacional, así como cierta experiencia en programación. Para más información, contactar directamente con Aurélien Decelle (`adecelle@ucm.es`) y Beatriz Seoane Bartolomé (`beseoane@ucm.es`).

Bibliography

[1] E. Agliari et al. "Machine learning and statistical physics: theory, inspiration, application". In: *Journal of Physics A: Special* 2020 (2020).

[2] A. Decelle and C. Furtlehner. "Restricted Boltzmann Machine, recent advances and mean-field theory". In: *Chinese Physics B* (2020).

[3] E. Gardner. "The space of interactions in neural network models". In: *Journal of physics A: Mathematical and general* 21.1 (1988), p. 257.

[4] Y. LeCun, Y. Bengio, and G. Hinton. "Deep learning". In: *nature* 521.7553 (2015), pp. 436–444.

[5] L. Zdeborová. "Understanding deep learning is also a job for physicists". In: *Nature Physics* 16.6 (2020), pp. 602–604.

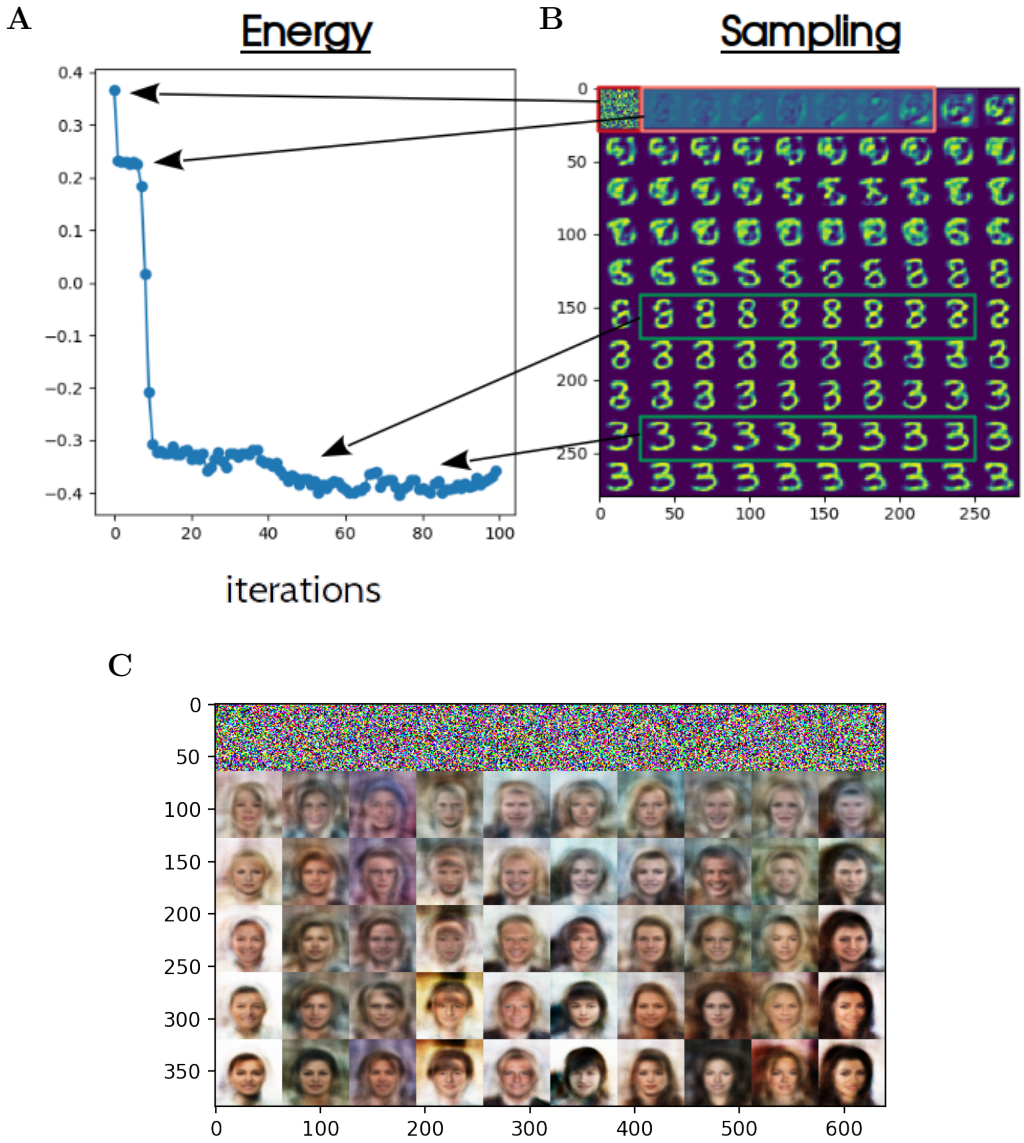

Figure 1: **A** Valores de la energía $E = -\sum_{ia} s_i w_{ia} \tau_a$ ajustada por una Restricted Boltzmann Machine (entrenada con una base de datos de números manuscritos) durante el proceso de *sampling* de la máquina. En **B** se muestra la evolución de las imágenes generadas por la máquina como función del número de iteraciones de Monte Carlo utilizadas en el sampling. En **C** se muestra la evolución de las muestras (en 10 simulaciones independientes) creadas por otra Restricted Boltzmann Machine entrenada con una base de datos de fotos de perfil.