



# Termodinámica Avanzada

Guía 4: Relaciones de trabajo, parte 2

*Jarzynski contraataca*



## ¿Qué sabemos hasta ahora?

- ▶ 2° Ley  $\rightarrow W \geq \Delta F = \Delta U - T\Delta S$  (trabajo hecho **sobre** el sistema)

## ¿Qué sabemos hasta ahora?

- ▶ 2° Ley  $\rightarrow W \geq \Delta F = \Delta U - T\Delta S$  (trabajo hecho **sobre** el sistema)
- ▶ La evolución del sistema y el trabajo estarán dados por las condiciones iniciales  $(x_i, p_i)$  y algún protocolo  $L(t)$

## ¿Qué sabemos hasta ahora?

- ▶ 2° Ley  $\rightarrow W \geq \Delta F = \Delta U - T\Delta S$  (trabajo hecho **sobre** el sistema)
- ▶ La evolución del sistema y el trabajo estarán dados por las condiciones iniciales  $(x_i, p_i)$  y algún protocolo  $L(t)$
- ▶ Dado el protocolo inverso  $L^*(t) \implies \Delta F^* = -\Delta F$  y por lo tanto  $W^* = -W \leq -\Delta F = \Delta F^* \rightarrow$  violación a la 2° Ley 😊

## ¿Qué sabemos hasta ahora?

- ▶ 2° Ley  $\rightarrow W \geq \Delta F = \Delta U - T\Delta S$  (trabajo hecho **sobre** el sistema)
- ▶ La evolución del sistema y el trabajo estarán dados por las condiciones iniciales  $(x_i, p_i)$  y algún protocolo  $L(t)$
- ▶ Dado el protocolo inverso  $L^*(t) \implies \Delta F^* = -\Delta F$  y por lo tanto  $W^* = -W \leq -\Delta F = \Delta F^* \rightarrow$  violación a la 2° Ley 😞
- ▶ Pero la 2° Ley tiene un carácter estadístico  $\implies \langle W \rangle \geq \Delta F$  y para sistemas **macroscópicos** las fluctuaciones están suprimidas 😊

## ¿Qué sabemos hasta ahora?

- ▶ 2º Ley  $\rightarrow W \geq \Delta F = \Delta U - T\Delta S$  (trabajo hecho **sobre** el sistema)
- ▶ La evolución del sistema y el trabajo estarán dados por las condiciones iniciales  $(x_i, p_i)$  y algún protocolo  $L(t)$
- ▶ Dado el protocolo inverso  $L^*(t) \implies \Delta F^* = -\Delta F$  y por lo tanto  $W^* = -W \leq -\Delta F = \Delta F^* \rightarrow$  violación a la 2º Ley 😞
- ▶ Pero la 2º Ley tiene un carácter estadístico  $\implies \langle W \rangle \geq \Delta F$  y para sistemas **macroscópicos** las fluctuaciones están suprimidas 😊

Las **relaciones de trabajo** ponen límites a las fluctuaciones

# Relaciones de trabajo

Crooks

$$\frac{\rho(W)}{\rho^*(-W)} = e^{\beta(W-\Delta F)}$$

Jarzynski

$$\langle e^{-\beta W} \rangle = e^{-\beta \Delta F}$$

Para un sistema macro no esperamos violaciones a la 2<sup>o</sup> Ley pero para un sistema micro, por ahí sí. Jarzynski nos limita estas posibles violaciones.

Crooks suprime (exponencialmente) las violaciones a la 2<sup>o</sup> Ley para el proceso inverso.

## Restricciones a la forma

Las relaciones de trabajo ponen restricciones tanto al **valor** (Jarzynski) de las fluctuaciones como a la **forma**.



## Restricciones a la forma

Las relaciones de trabajo ponen restricciones tanto al **valor** (Jarzynski) de las fluctuaciones como a la **forma**.

Dada  $\rho^*(W)$  gaussiana, veamos que  $\rho(W)$  también debe serlo:

## Ejercicio 2

$$\rho(W) = e^{\beta(W-\Delta F)} \frac{1}{\sqrt{2\pi\sigma_*^2}} e^{-\frac{(-W-\bar{W}^*)^2}{2\sigma_*^2}}$$

## Ejercicio 2

$$\begin{aligned}\rho(W) &= e^{\beta(W-\Delta F)} \frac{1}{\sqrt{2\pi\sigma_*^2}} e^{-\frac{(-W-\bar{W}^*)^2}{2\sigma_*^2}} \\ &= \frac{e^{-\beta\Delta F}}{\sqrt{2\pi\sigma_*^2}} e^{-\frac{1}{2\sigma_*^2}[(-W-\bar{W}^*)^2-2\sigma_*^2\beta W]}\end{aligned}$$

## Ejercicio 2

$$\begin{aligned}\rho(W) &= e^{\beta(W-\Delta F)} \frac{1}{\sqrt{2\pi\sigma_*^2}} e^{-\frac{(-W-\bar{W}^*)^2}{2\sigma_*^2}} \\ &= \frac{e^{-\beta\Delta F}}{\sqrt{2\pi\sigma_*^2}} e^{-\frac{1}{2\sigma_*^2} [(-W-\bar{W}^*)^2 - 2\sigma_*^2\beta W]} \\ &= \frac{e^{-\beta\Delta F}}{\sqrt{2\pi\sigma_*^2}} e^{-\frac{1}{2\sigma_*^2} [(W-(\sigma_*^2\beta-\bar{W}^*))^2 - (\sigma_*^2\beta-\bar{W}^*)^2 + (\bar{W}^*)^2]}\end{aligned}$$

## Ejercicio 2

$$\begin{aligned}\rho(W) &= e^{\beta(W-\Delta F)} \frac{1}{\sqrt{2\pi\sigma_*^2}} e^{-\frac{(-W-\bar{W}^*)^2}{2\sigma_*^2}} \\ &= \frac{e^{-\beta\Delta F}}{\sqrt{2\pi\sigma_*^2}} e^{-\frac{1}{2\sigma_*^2} [(-W-\bar{W}^*)^2 - 2\sigma_*^2\beta W]} \\ &= \frac{e^{-\beta\Delta F}}{\sqrt{2\pi\sigma_*^2}} e^{-\frac{1}{2\sigma_*^2} [(W-(\sigma_*^2\beta-\bar{W}^*))^2 - (\sigma_*^2\beta-\bar{W}^*)^2 + (\bar{W}^*)^2]} \\ &= \frac{C}{\sqrt{2\pi\sigma_*^2}} e^{-\frac{1}{2\sigma_*^2} [W-(\sigma_*^2\beta-\bar{W}^*)]^2}\end{aligned}$$

$\implies$  es una gaussiana con varianza  $\sigma_*^2 = \sigma$  y valor medio  $\bar{W} = \beta\sigma_*^2 - \bar{W}^*$

## Ejercicio 2

$$\bar{W} = \beta\sigma_*^2 - \bar{W}^* \quad \Rightarrow \quad \boxed{\bar{W} + \bar{W}^* = \beta\sigma_*^2}$$

## Ejercicio 2

$$\overline{W} = \beta\sigma_*^2 - \overline{W}^* \implies \boxed{\overline{W} + \overline{W}^* = \beta\sigma_*^2}$$

Además por normalización (la integral debe dar 1)

$$C = 1 \iff \frac{(\beta\sigma_*^2 - \overline{W}^*)^2 - (\overline{W}^*)^2}{2\sigma^2} - \beta\Delta F = 0$$

## Ejercicio 2

$$\overline{W} = \beta\sigma_*^2 - \overline{W}^* \implies \boxed{\overline{W} + \overline{W}^* = \beta\sigma_*^2}$$

Además por normalización (la integral debe dar 1)

$$C = 1 \iff \frac{(\beta\sigma_*^2 - \overline{W}^*)^2 - (\overline{W}^*)^2}{2\sigma^2} - \beta\Delta F = 0$$

$$\boxed{\overline{W} - \overline{W}^* = 2\Delta F}$$



# Implicancias

$$\overline{W} - \overline{W}^* = 2\Delta F$$

Podemos medir  $\Delta F$  a partir de  $\overline{W}$  y  $\overline{W}^*$ .


$$\overline{W} + \overline{W}^* = \beta\sigma_*^2$$

Es un teorema de *fluctuación-disipación*:  $\beta\sigma_*^2 = 2(\overline{W} - \Delta F) \rightarrow$  cuanto más irreversible es el proceso, más fluctuaciones.

# Una aplicación



## El sistema



- ▶  $k = m\omega^2$
- ▶  $H = \frac{p^2}{2m} + \frac{1}{2}m\omega^2[x^2 + (x - L)^2]$
- ▶ Si  $t < 0 \rightarrow L(t) = L_i$  y en eq. con un reservorio a  $T$ .
- ▶ Si  $0 < t < \tau \rightarrow$  se aísla del reservorio y  $L(t) = L_i + vt$ ,  $v = \text{cte}$ .

Nos puede interesar calcular  $\Delta F$ , ver las fluctuaciones, estudiar las probabilidades, etc.

# Procedimiento

## Energía libre

$\Delta F = F(L_f) - F(L_i)$ . Recordando que  $F = -kT \ln Z$

$$e^{-\beta \Delta F} = \frac{Z_f}{Z_i}$$

# Procedimiento

## Energía libre

$\Delta F = F(L_f) - F(L_i)$ . Recordando que  $F = -kT \ln Z$

$$e^{-\beta \Delta F} = \frac{Z_f}{Z_i}$$

En este problema,

$$Z(L) = Ae^{-\frac{\beta m \omega^2 L^2}{4}} \implies \Delta F = \frac{m \omega^2}{4} (L_f^2 - L_i^2) = \frac{m \omega^2}{4} v_T (2L_i + v_T)$$

# Procedimiento

## Densidad de probabilidad

Sabiendo la densidad de probabilidad<sup>1</sup>  $\rho(x_i, p_i)$ , usamos la guía 1

$$\rho(W) = \int dx_i dp_i \rho(x_i, p_i) \delta(W - W(x_i, p_i))$$

con  $\rho(x_i, p_i) = e^{-\beta H} / Z(L_i)$ .

---

<sup>1</sup>Cada realización del proceso depende del estado microscópico inicial del sistema que depende de las variables aleatorias iniciales  $x_i$  y  $p_i$ . La dens. de prob. estará dada por el ensamble canónico.

# Procedimiento

## Densidad de probabilidad

Sabiendo la densidad de probabilidad  $\rho(x_i, p_i)$ , usamos la guía 1

$$\rho(W) = \int dx_i dp_i \rho(x_i, p_i) \delta(W - W(x_i, p_i))$$

con  $\rho(x_i, p_i) = e^{-\beta H} / Z(L_i)$ . Para hallar  $W(x_i, p_i)$ ,

$$W(x_i, p_i) = \int_0^\tau dt \dot{L}(t) \frac{\partial H}{\partial L}(x(t), p(t); L(t))$$

# Procedimiento

## Densidad de probabilidad

Sabiendo la densidad de probabilidad  $\rho(x_i, p_i)$ , usamos la guía 1

$$\rho(W) = \int dx_i dp_i \rho(x_i, p_i) \delta(W - W(x_i, p_i))$$

con  $\rho(x_i, p_i) = e^{-\beta H} / Z(L_i)$ . Para hallar  $W(x_i, p_i)$ ,

$$W(x_i, p_i) = \int_0^\tau dt \dot{L}(t) \frac{\partial H}{\partial L}(x(t), p(t); L(t))$$

Pero vamos a necesitar  $x = x(t, x_i, p_i)$

$$\ddot{x} + 2\omega^2 x = \omega^2 L(t), \quad x(0) = x_i, \dot{x}(0) = p_i/m$$



## Resultados

Para este problema,

$$x(t) = \frac{L_i + vt}{2} - \frac{L_i - 2x_i}{2} \cos(\omega_0 t) + \frac{2p_i - mv}{2m\omega_0} \sin(\omega_0 t)$$

$$W(x_i, p_i) = \frac{mv\omega_0^2}{2} \left\{ \frac{\tau}{4} (2L_i + v\tau) + \frac{L_i - 2x_i}{2\omega_0} \sin(\omega_0 t) - \frac{2p_i - mv}{2m\omega_0^2} (1 - \cos(\omega_0 t)) \right\}$$

donde  $\omega_0^2 = 2\omega^2$ .

## Resultados

Para este problema,

$$x(t) = \frac{L_i + vt}{2} - \frac{L_i - 2x_i}{2} \cos(\omega_0 t) + \frac{2p_i - mv}{2m\omega_0} \sin(\omega_0 t)$$

$$W(x_i, p_i) = \frac{mv\omega_0^2}{2} \left\{ \frac{\tau}{4} (2L_i + v\tau) + \frac{L_i - 2x_i}{2\omega_0} \sin(\omega_0 t) - \frac{2p_i - mv}{2m\omega_0^2} (1 - \cos(\omega_0 t)) \right\}$$

donde  $\omega_0^2 = 2\omega^2$ . Notemos que  $\rho(x_i, p_i)$  es gaussiana, por lo tanto  $\rho(W)$  también lo será  $\rightarrow$  podemos calcular directamente  $\sigma^2$  y  $\overline{W}$ ,

$$\overline{W} = \frac{mv\omega^2}{4} \left[ \frac{v}{\omega^2} (1 - \cos(\omega_0\tau)) + \tau(2L_i + v\tau) \right]$$


$$\sigma^2 = \langle (W - \overline{W})^2 \rangle = \frac{mv^2}{2\beta} (1 - \cos(\omega_0\tau))$$

# Resultados

Entonces resulta

$$\rho(W) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(W-\bar{W})^2}{2\sigma^2}}, \quad \rho^*(W) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(W-\bar{W}^*)^2}{2\sigma^2}}$$

con  $\bar{W}^* = \beta\sigma^2 - \bar{W}$  en donde para el proceso inverso hay que tener en cuenta que  $L_i^* = L_f = L_i + v\tau$ ,  $v^* = -v$ .



## Otros sistemas conocidos



# Algunos ejemplos

## Movimiento browniano

Una partícula en un potencial  $V_\lambda(x) = \frac{1}{2}k(x - \lambda)^2$ ,

$$\dot{x} = -\frac{k}{\gamma}(x - \lambda) + \xi(t)$$

con  $\gamma$ : coef. de viscosidad y  $\xi(t)$  un término de ruido tal que  $\langle \xi(t)\xi(t') \rangle \sim \delta(t - t')$ .

# Algunos ejemplos

## Movimiento browniano

Una partícula en un potencial  $V_\lambda(x) = \frac{1}{2}k(x - \lambda)^2$ ,

$$\dot{x} = -\frac{k}{\gamma}(x - \lambda) + \xi(t)$$

con  $\gamma$ : coef. de viscosidad y  $\xi(t)$  un término de ruido tal que  $\langle \xi(t)\xi(t') \rangle \sim \delta(t - t')$ . El trabajo

$$W = \int_0^\tau dt \dot{\lambda} \frac{\partial H}{\partial \lambda} \iff \dot{W} = -k\dot{\lambda}(x - \lambda t)$$

# Algunos ejemplos

## Movimiento browniano

Una partícula en un potencial  $V_\lambda(x) = \frac{1}{2}k(x - \lambda)^2$ ,

$$\dot{x} = -\frac{k}{\gamma}(x - \lambda) + \xi(t)$$

con  $\gamma$ : coef. de viscosidad y  $\xi(t)$  un término de ruido tal que  $\langle \xi(t)\xi(t') \rangle \sim \delta(t - t')$ . El trabajo

$$W = \int_0^\tau dt \dot{\lambda} \frac{\partial H}{\partial \lambda} \iff \dot{W} = -k\dot{\lambda}(x - \dot{\lambda}t)$$

## Cadena de spin

$$H = \sum_i J\sigma_i\sigma_{i+1} - B(t) \sum_i \sigma_i \implies \dot{W} = -\dot{B}(t) \sum_i \sigma_i$$

## Cálculos

A veces obtener soluciones analíticas no es sencillo; además, muchas veces no se puede obtener una expresión para  $\Delta F \implies$  se mide  $\rho(W)/\rho^*(-W)$  y se repite muchas veces el mismo protocolo para obtener estadística. Esto nos asegura que trayectorias muy poco probables no realicen contribuciones significativas al valor medio (estadística grande).



# Cálculos

A veces obtener soluciones analíticas no es sencillo; además, muchas veces no se puede obtener una expresión para  $\Delta F \implies$  se mide  $\rho(W)/\rho^*(-W)$  y se repite muchas veces el mismo protocolo para obtener estadística. Esto nos asegura que trayectorias muy poco probables no realicen contribuciones significativas al valor medio (estadística grande)

—→ otra forma de obtener el trabajo es generando trayectorias (muestras) de acuerdo a la dinámica del sistema.

Article | Published: 21 September 2020

## Machine learning the thermodynamic arrow of time

Alireza Seif , Mohammad Hafezi & Christopher Jarzynski

*Nature Physics* (2020) | Cite this article

**3937** Accesses | **185** Altmetric | Metrics

<https://www.nature.com/articles/s41567-020-1018-2>  
(<https://arxiv.org/pdf/1909.12380.pdf>)

# Sobre el paper

## Idea

- ▶ Sistemas macroscópicos poseen una *flecha del tiempo*; sistemas microscópicos pueden ser reversibles en el tiempo (violación de la 2<sup>o</sup> Ley).
- ▶ Sin embargo, las fluctuaciones pueden volver difusa la flecha de tiempo.
- ▶ Generando trayectorias microscópicas (directas y reversas) → ¿ML puede adivinar la dirección de la flecha de tiempo?. Es decir, distinguir entre una trayectoria directa e inversa.

# Sobre el paper

## Idea

- ▶ Sistemas macroscópicos poseen una *flecha del tiempo*; sistemas microscópicos pueden ser reversibles en el tiempo (violación de la 2<sup>o</sup> Ley).
- ▶ Sin embargo, las fluctuaciones pueden volver difusa la flecha de tiempo.
- ▶ Generando trayectorias microscópicas (directas y reversas) → ¿ML puede adivinar la dirección de la flecha de tiempo?. Es decir, distinguir entre una trayectoria directa e inversa.

## Resultados

- ▶ Dada una trayectoria microscópica (input), el algoritmo puede discernir entre las direcciones del tiempo.
- ▶ En los casos donde la flecha no está muy clara, puede obtener la probabilidad de que ese proceso ocurra.
- ▶ A su vez, puede obtener la termodinámica y la física detrás del proceso (trabajo, entropía, etc).

# Resultados




Figure: Browniano




Figure: Cadena spin

- ▶ Línea negra: probabilidad teórica // Nube gris: output de la red neuronal (simulaciones)