

# **Aprendizaje profundo basado en la física**

**Semana 6: De simulaciones a inferencia**


**Docente: José I. Robledo - 14/05/2026**

# De simulaciones a inferencia


## Introducción a la estadística Bayesiana

- Estadística frecuentista: estimar parámetros *poblacionales* de distribuciones subyacentes a las mediciones. *Existen* los parámetros poblacionales y nosotros tratamos de buscarlos.
- Estadística Bayesiana: los parámetros del modelo son *variables aleatorias*. Nuestra incertidumbre sobre ellos se describe mediante sus distribuciones de probabilidad.


DID THE SUN JUST EXPLODE?  
(IT'S NIGHT, SO WE'RE NOT SURE.)



FREQUENTIST STATISTICIAN:



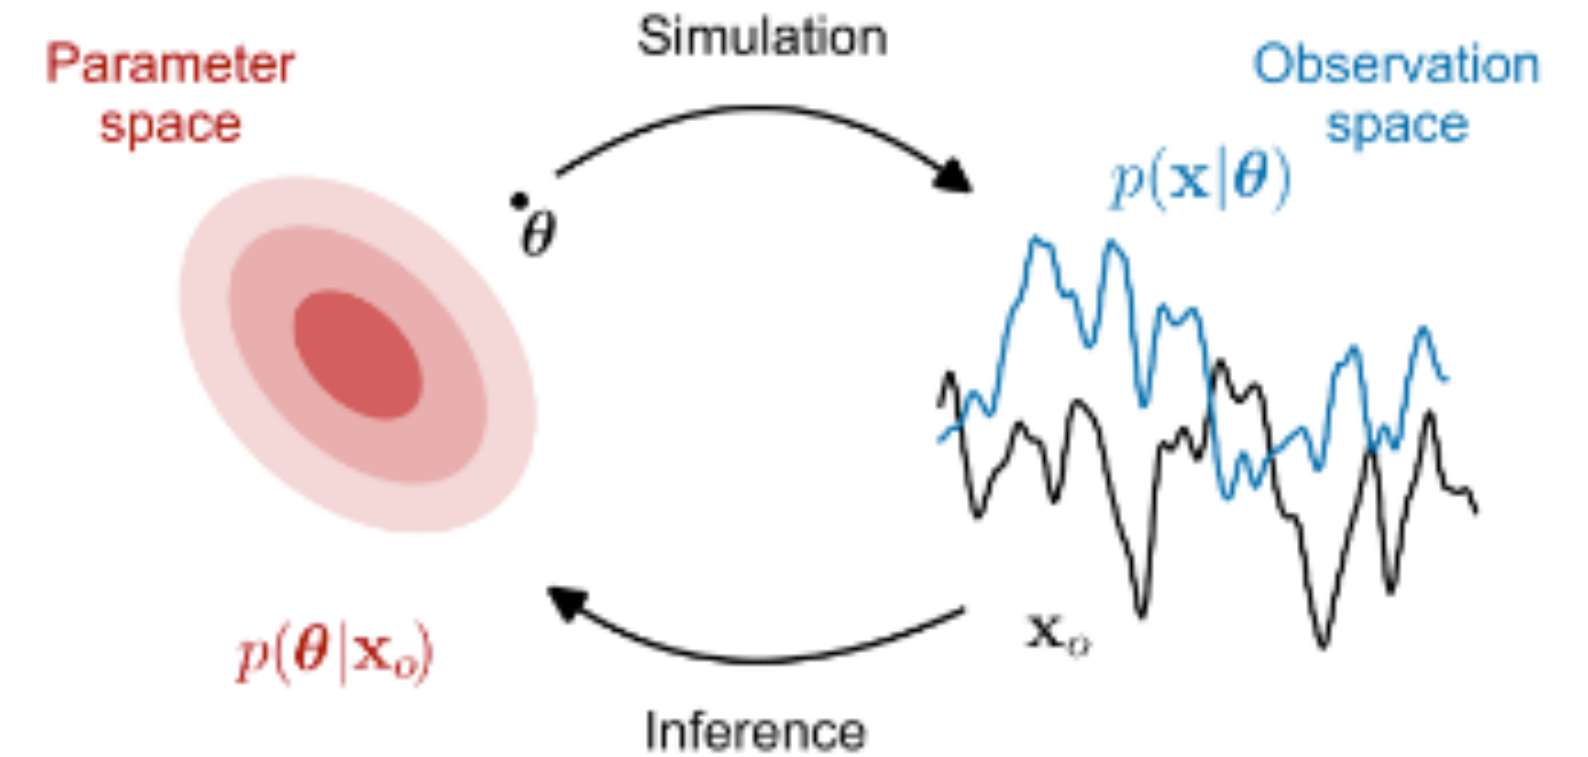
BAYESIAN STATISTICIAN:



# Estadística Bayesiana

## Teorema de Bayes

Buscamos construir una distribución de probabilidad sobre los parámetros que refleje lo que sabemos antes de observar los datos y cómo la información se actualiza luego de observarlos



*a posteriori*      *Verosimilitud*      *a priori*

$$p(\theta | x) = \frac{p(x | \theta)p(\theta)}{p(x)}$$

*evidencia*

*Actualizar creencias usando observaciones.*

$$P(\text{lie}) = 1/36$$

$$P(\text{exploded}) = 1/4.38 \times 10^{13}$$

$$\begin{aligned} P(\text{exploded} | \text{yes}) &= \frac{P(\text{yes} | \text{exploded})P(\text{exploded})}{P(\text{yes})} \\ &= \frac{P(\text{exploded})(1 - P(\text{lie}))}{P(\text{exploded})(1 - P(\text{lie})) + P(\text{lie})(1 - P(\text{exploded}))} \\ &\approx \frac{1}{1.25226 \times 10^{12}} \end{aligned}$$

La verosimilitud muchas veces no la podemos escribir analíticamente

$p(x | \theta) \rightarrow$  simulador muestrea la verosimilitud

# Estadística Bayesiana

## Problema

$$p(\theta | x) = \frac{p(x | \theta)p(\theta)}{p(x)}$$

$$p(x) = \int p(x | \theta)p(\theta)d\theta$$

## Solución

Cuando no se puede resolver analíticamente  $p(x)$  pero se conoce  $p(x | \theta)$ , entonces se recurre a métodos de muestreo como:

- Metropolis-Hasting
- Hamiltonian Monte-Carlo
- Gibbs sampling

Con los que se evita calcular esta integral usando cadenas de Markov (MCMC) para estimar la distribución a posteriori!

# Estadística Bayesiana

## Metropolis Hasting

$$p(\theta | x) = \frac{p(x | \theta)p(\theta)}{p(x)}$$

Muy inteligentemente:

- Empezamos de un valor inicial  $\theta_t$  y proponemos  $\theta'$  usando una distribución de propuesta (típicamente aleatoria), i.e.  $\theta' \sim q(\theta' | \theta_t)$
- Comparamos que tan probable es el nuevo estado  $\theta'$  respecto a  $\theta_t$  usando el cociente de las posteriores respectivas. Si la probabilidad posterior es mayor, entonces nos quedamos con la propuesta. Tasa de aceptación:


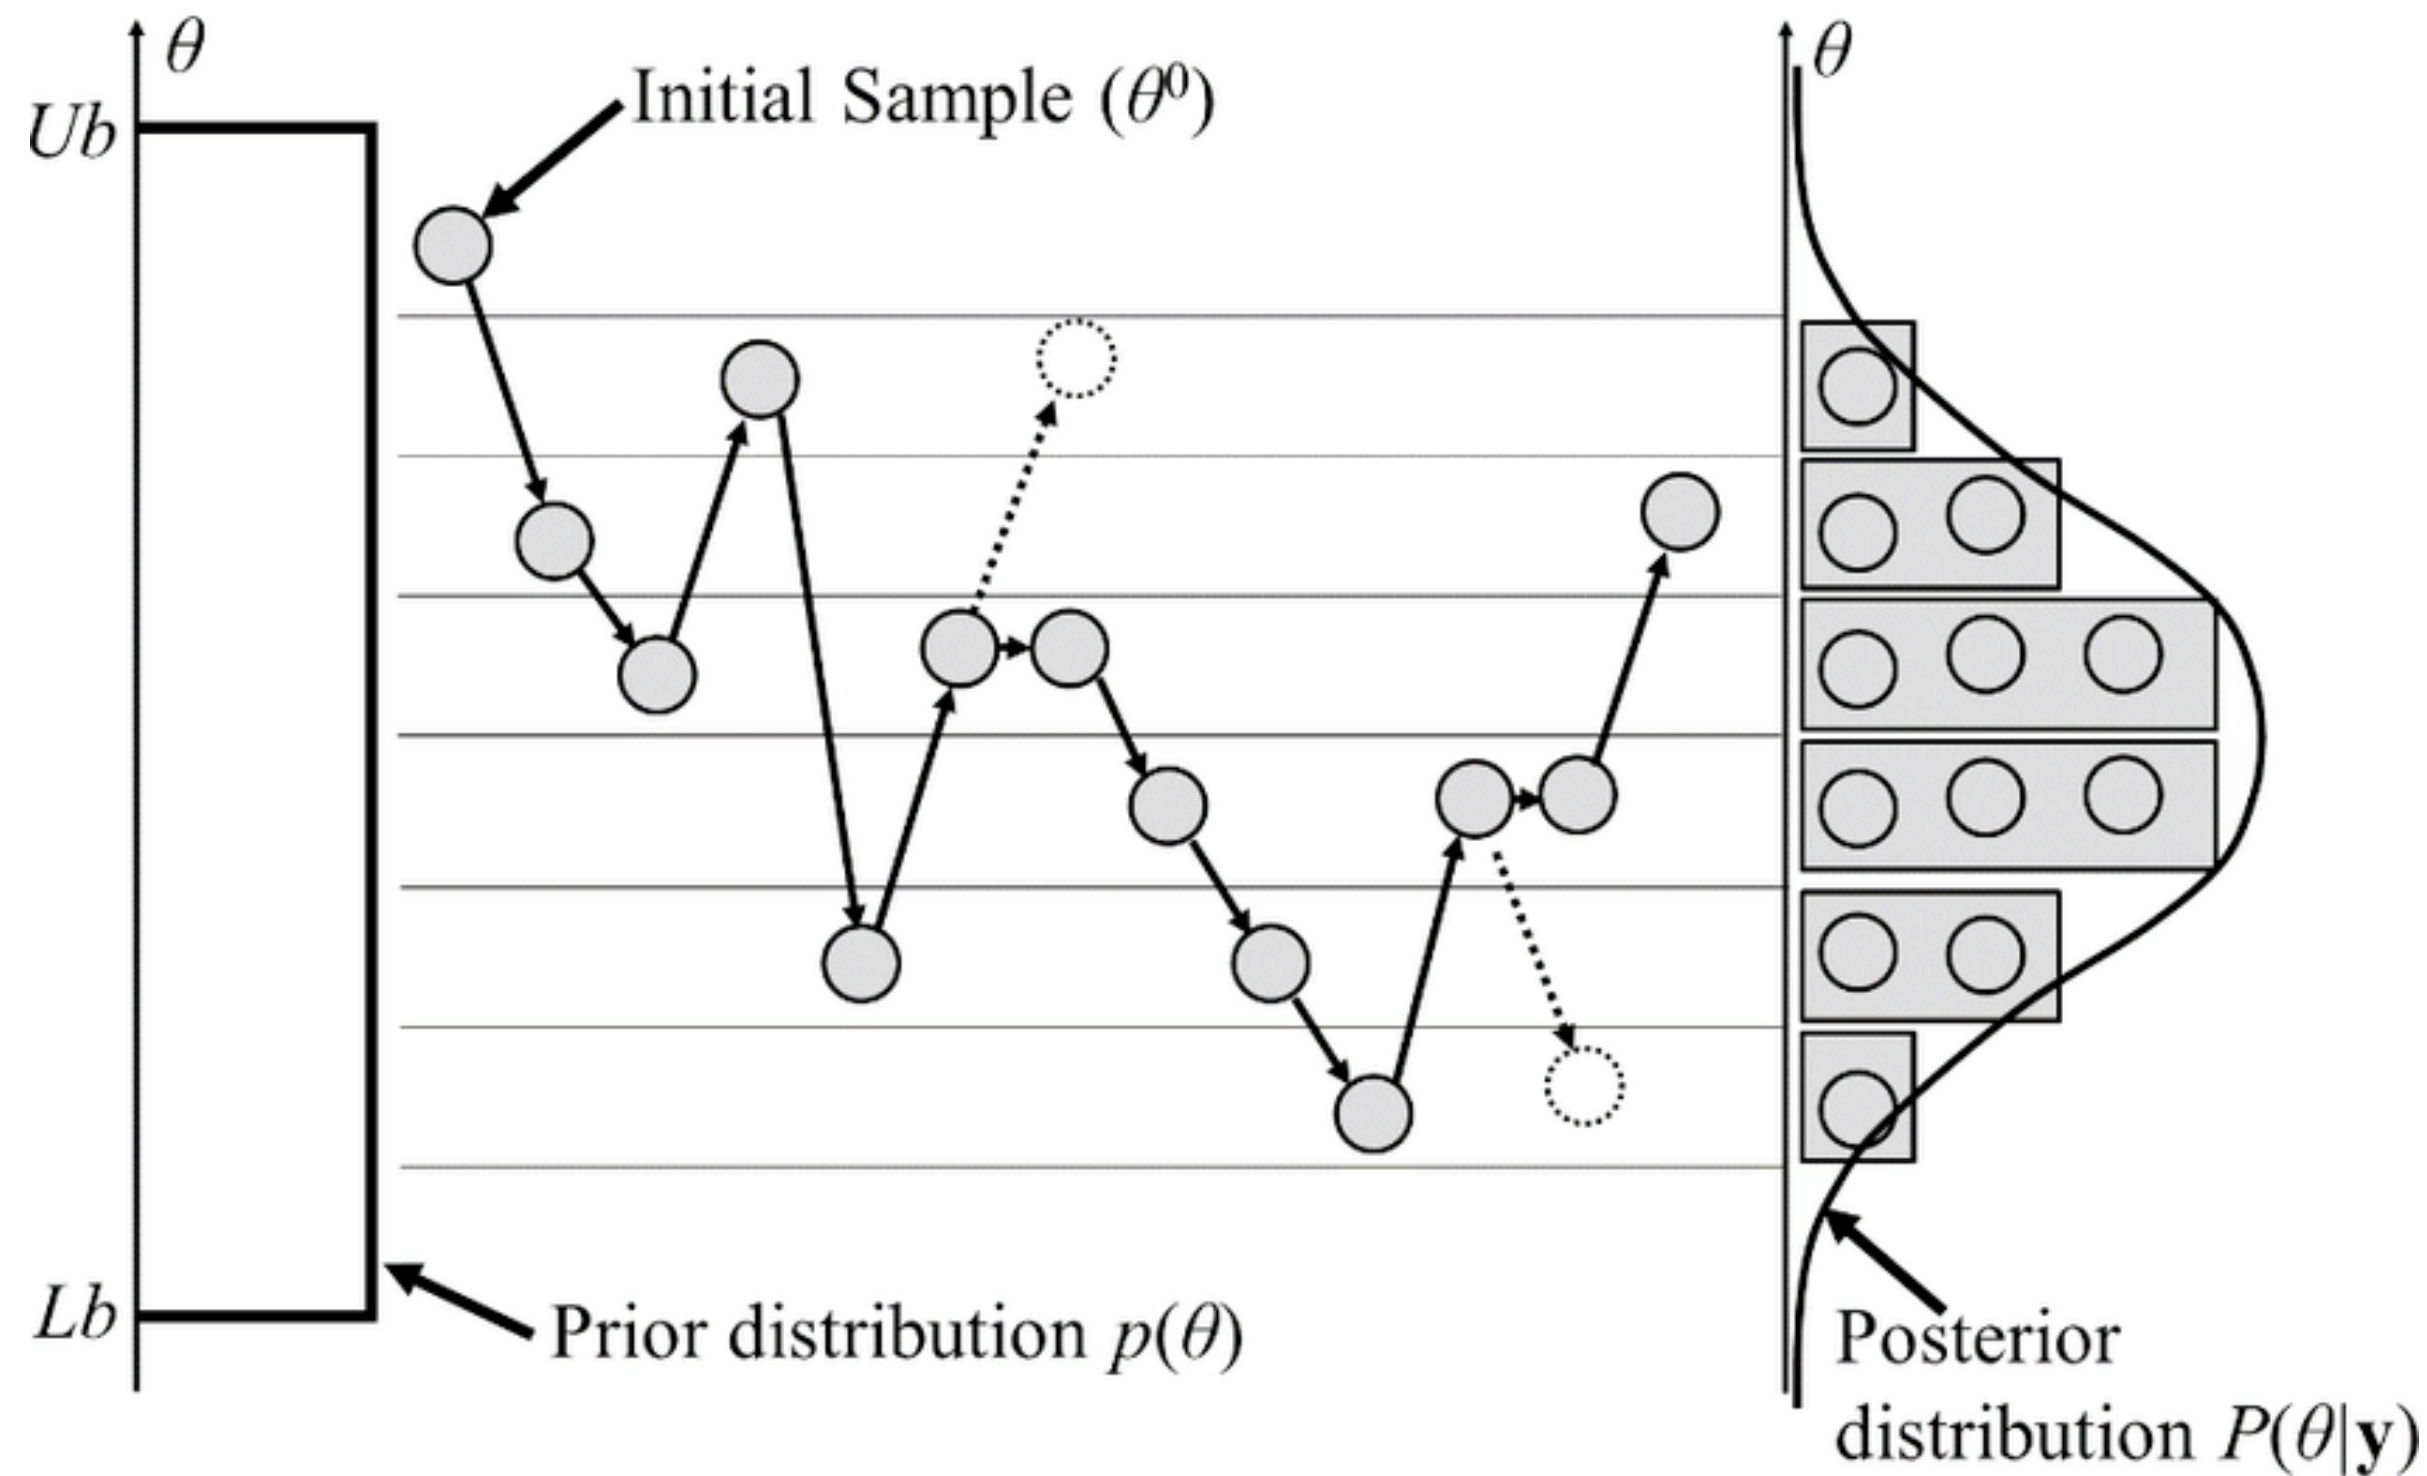
$$\alpha = \min \left( 1, \frac{p(\theta' | x)}{p(\theta_t | x)} \right) = \min \left( 1, \frac{p(x | \theta')p(\theta')}{p(x | \theta_t)p(\theta_t)} \right)$$

*Si el nuevo punto explica mejor los datos, nos lo quedamos. Si es peor, todavía hay una probabilidad que lo aceptemos y es proporcional a cuánto menor es la posterior respecto al estado anterior.*

# Estadística Bayesiana

## Metropolis Hasting

$$p(\theta | x) = \frac{p(x | \theta)p(\theta)}{p(x)}$$



$$\theta^{(1)}, \theta^{(2)}, \dots, \theta^{(N)} \sim p(\theta | x) \implies \mathbb{E}[f(\theta)] = \int f(\theta)p(\theta | x)d\theta \approx \frac{1}{N} \sum_{i=1}^N f(\theta^{(i)})$$

MCMC

# Inferencia Basada en Simulaciones

## Motivación

Muchos sistemas físicos:

- Tienen simuladores complejos
- Poseen ruido no gaussiano
- Tienen dinámicas altamente no lineales
- ***Resulta imposible escribir la verosimilitud de forma explícita.***

Cosmología

Dinámica Molecular

Inferencia climática

Física de partículas

Sistemas cuánticos

# Inferencia Basada en Simulaciones

## Primera idea: Approximate Bayesian Computation

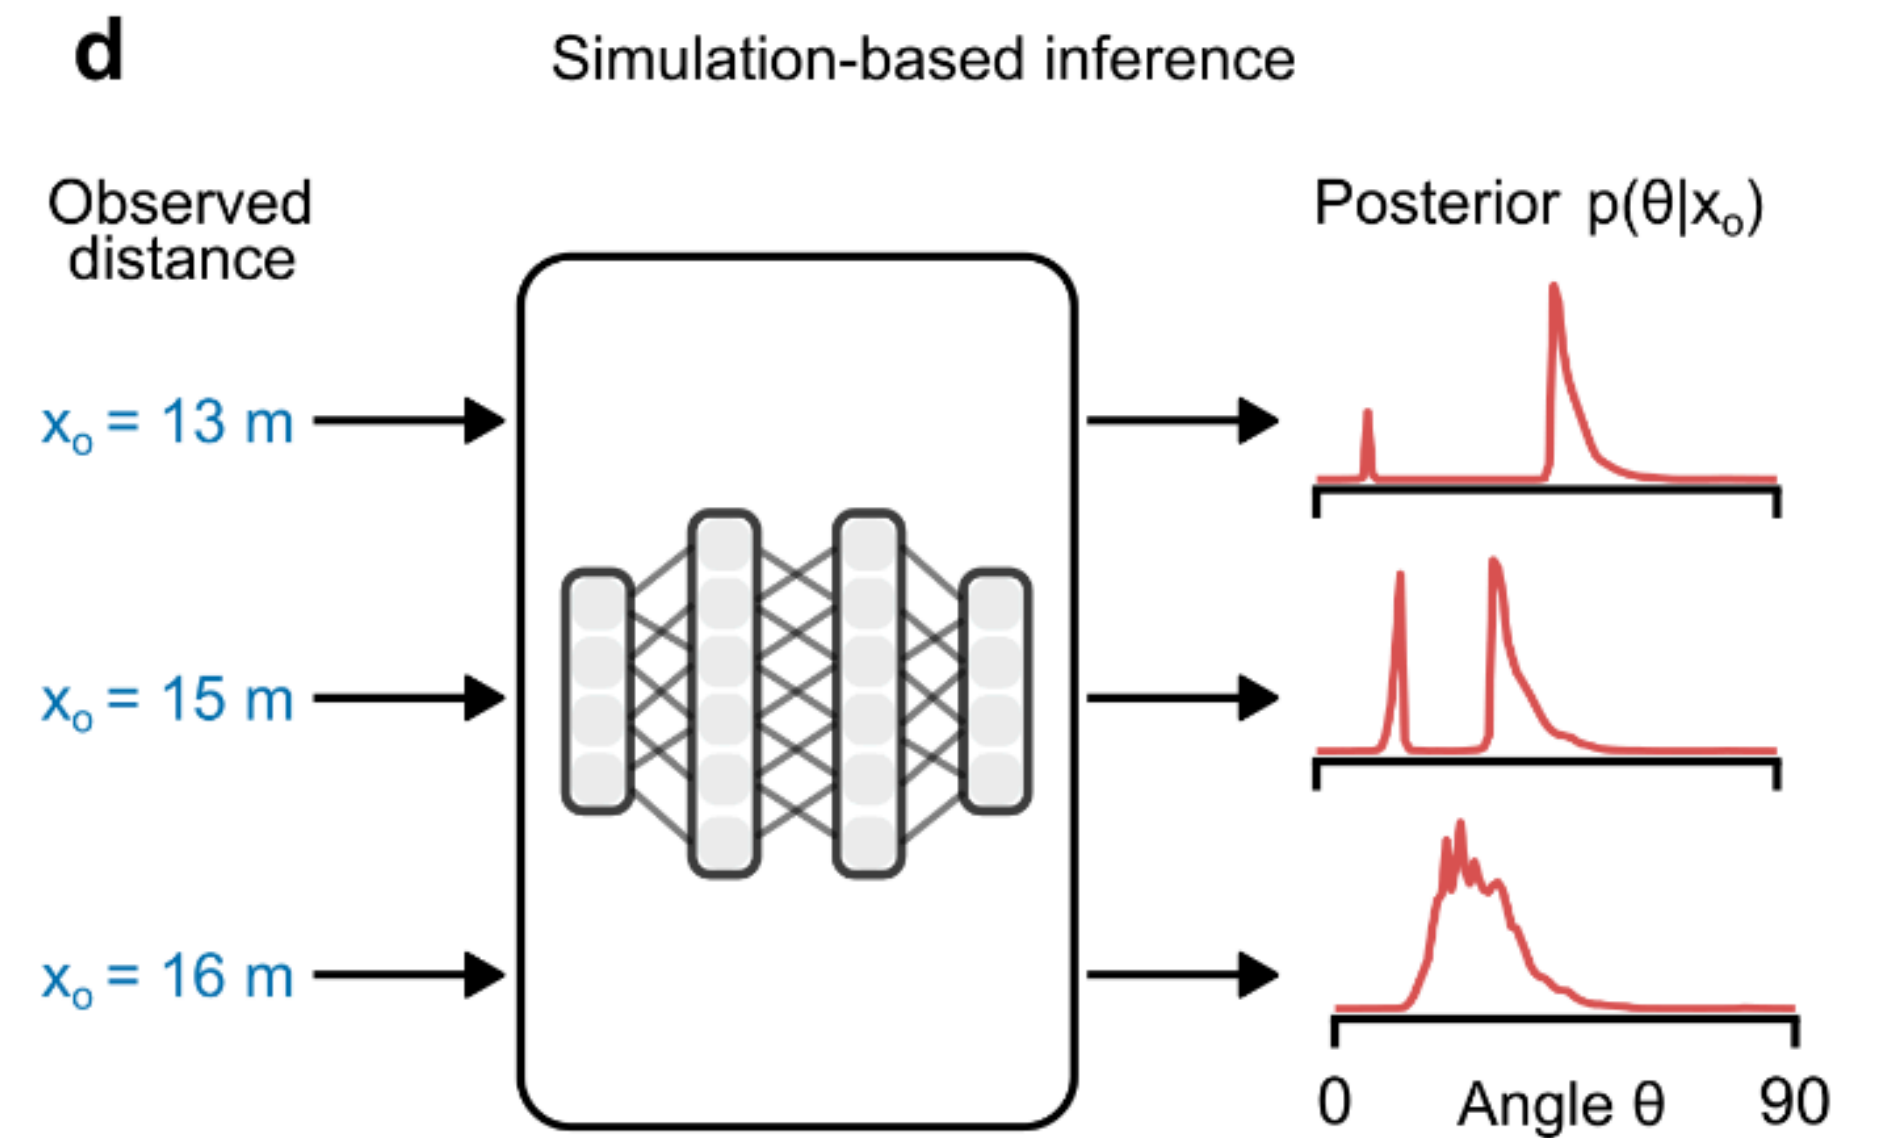
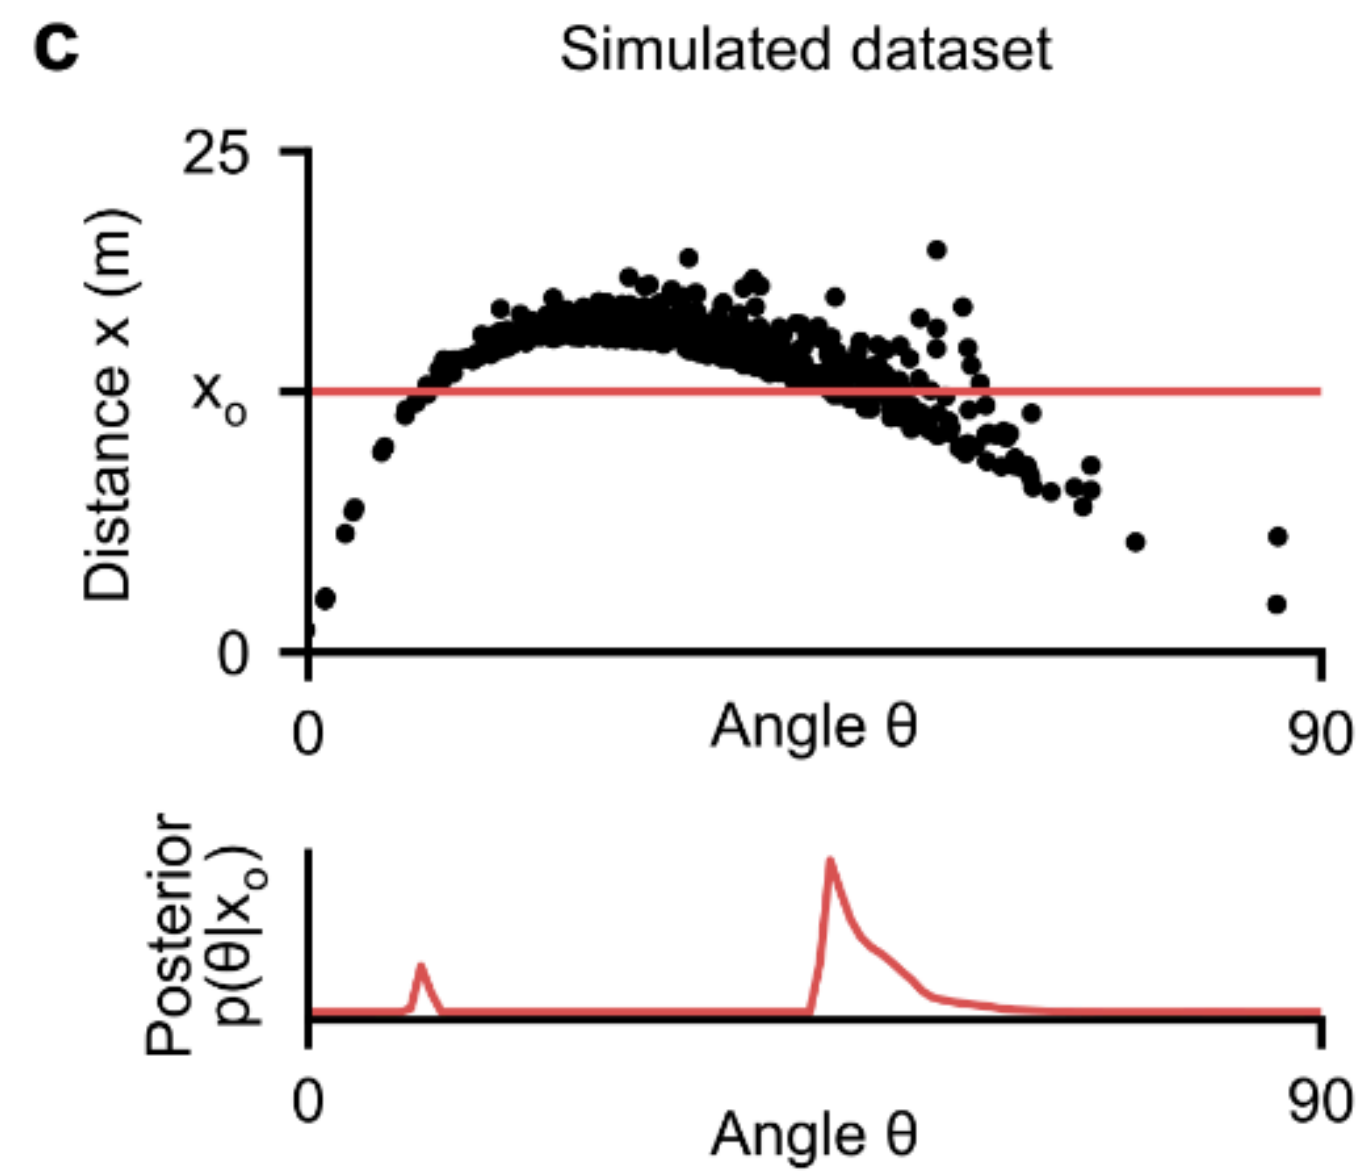
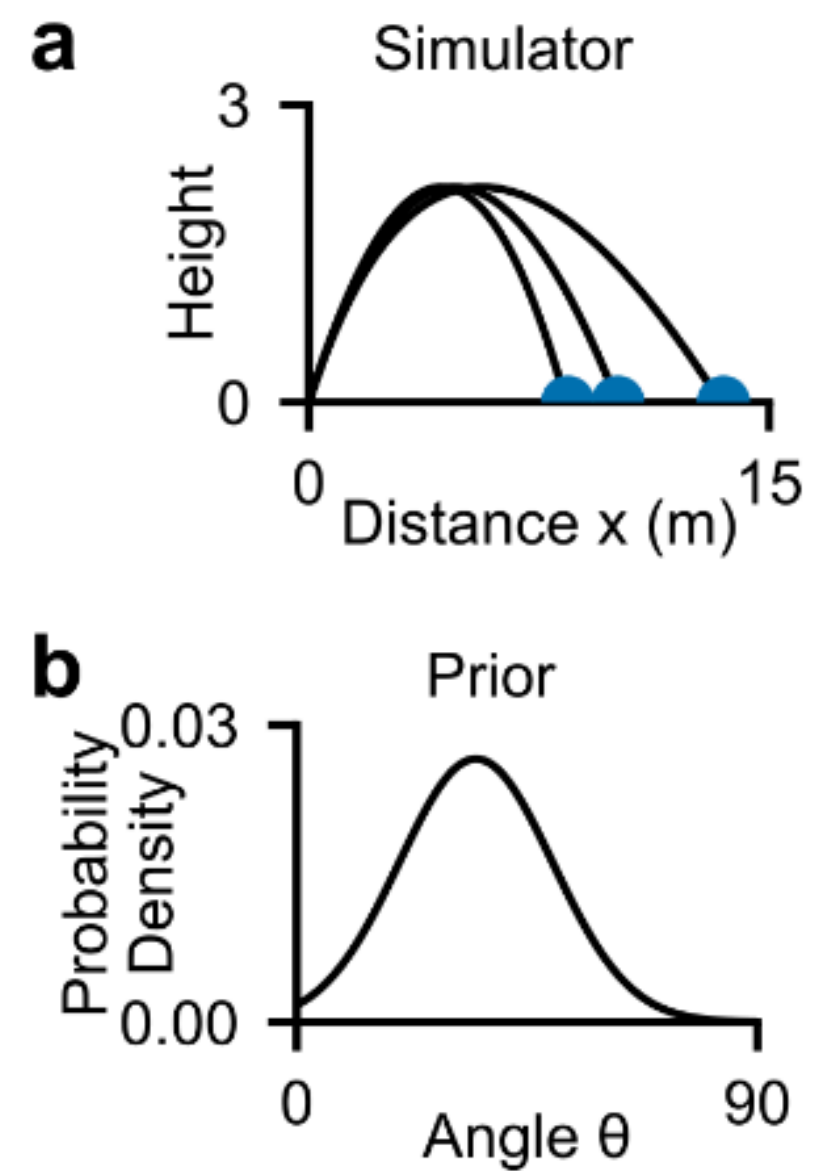
- El método de **Cómputo Bayesiano Aproximado** :
  - Muestra  $\theta$  de nuestra creencia a priori  $p(\theta)$ .
  - Simula datos  $x_{sim}$  para los parámetros  $\theta$ , i.e.  $x_{sim} \sim p(x | \theta)$
  - Compara simulaciones con  $x_{obs}$  para ver si decidimos aceptar o no según algún criterio de distancia, como por ej.

$$d(x_{sim}, x_{obs}) < \epsilon$$

Si se cumple, se acepta, sino se descarta. No nos hace falta la verosimilitud explícita!

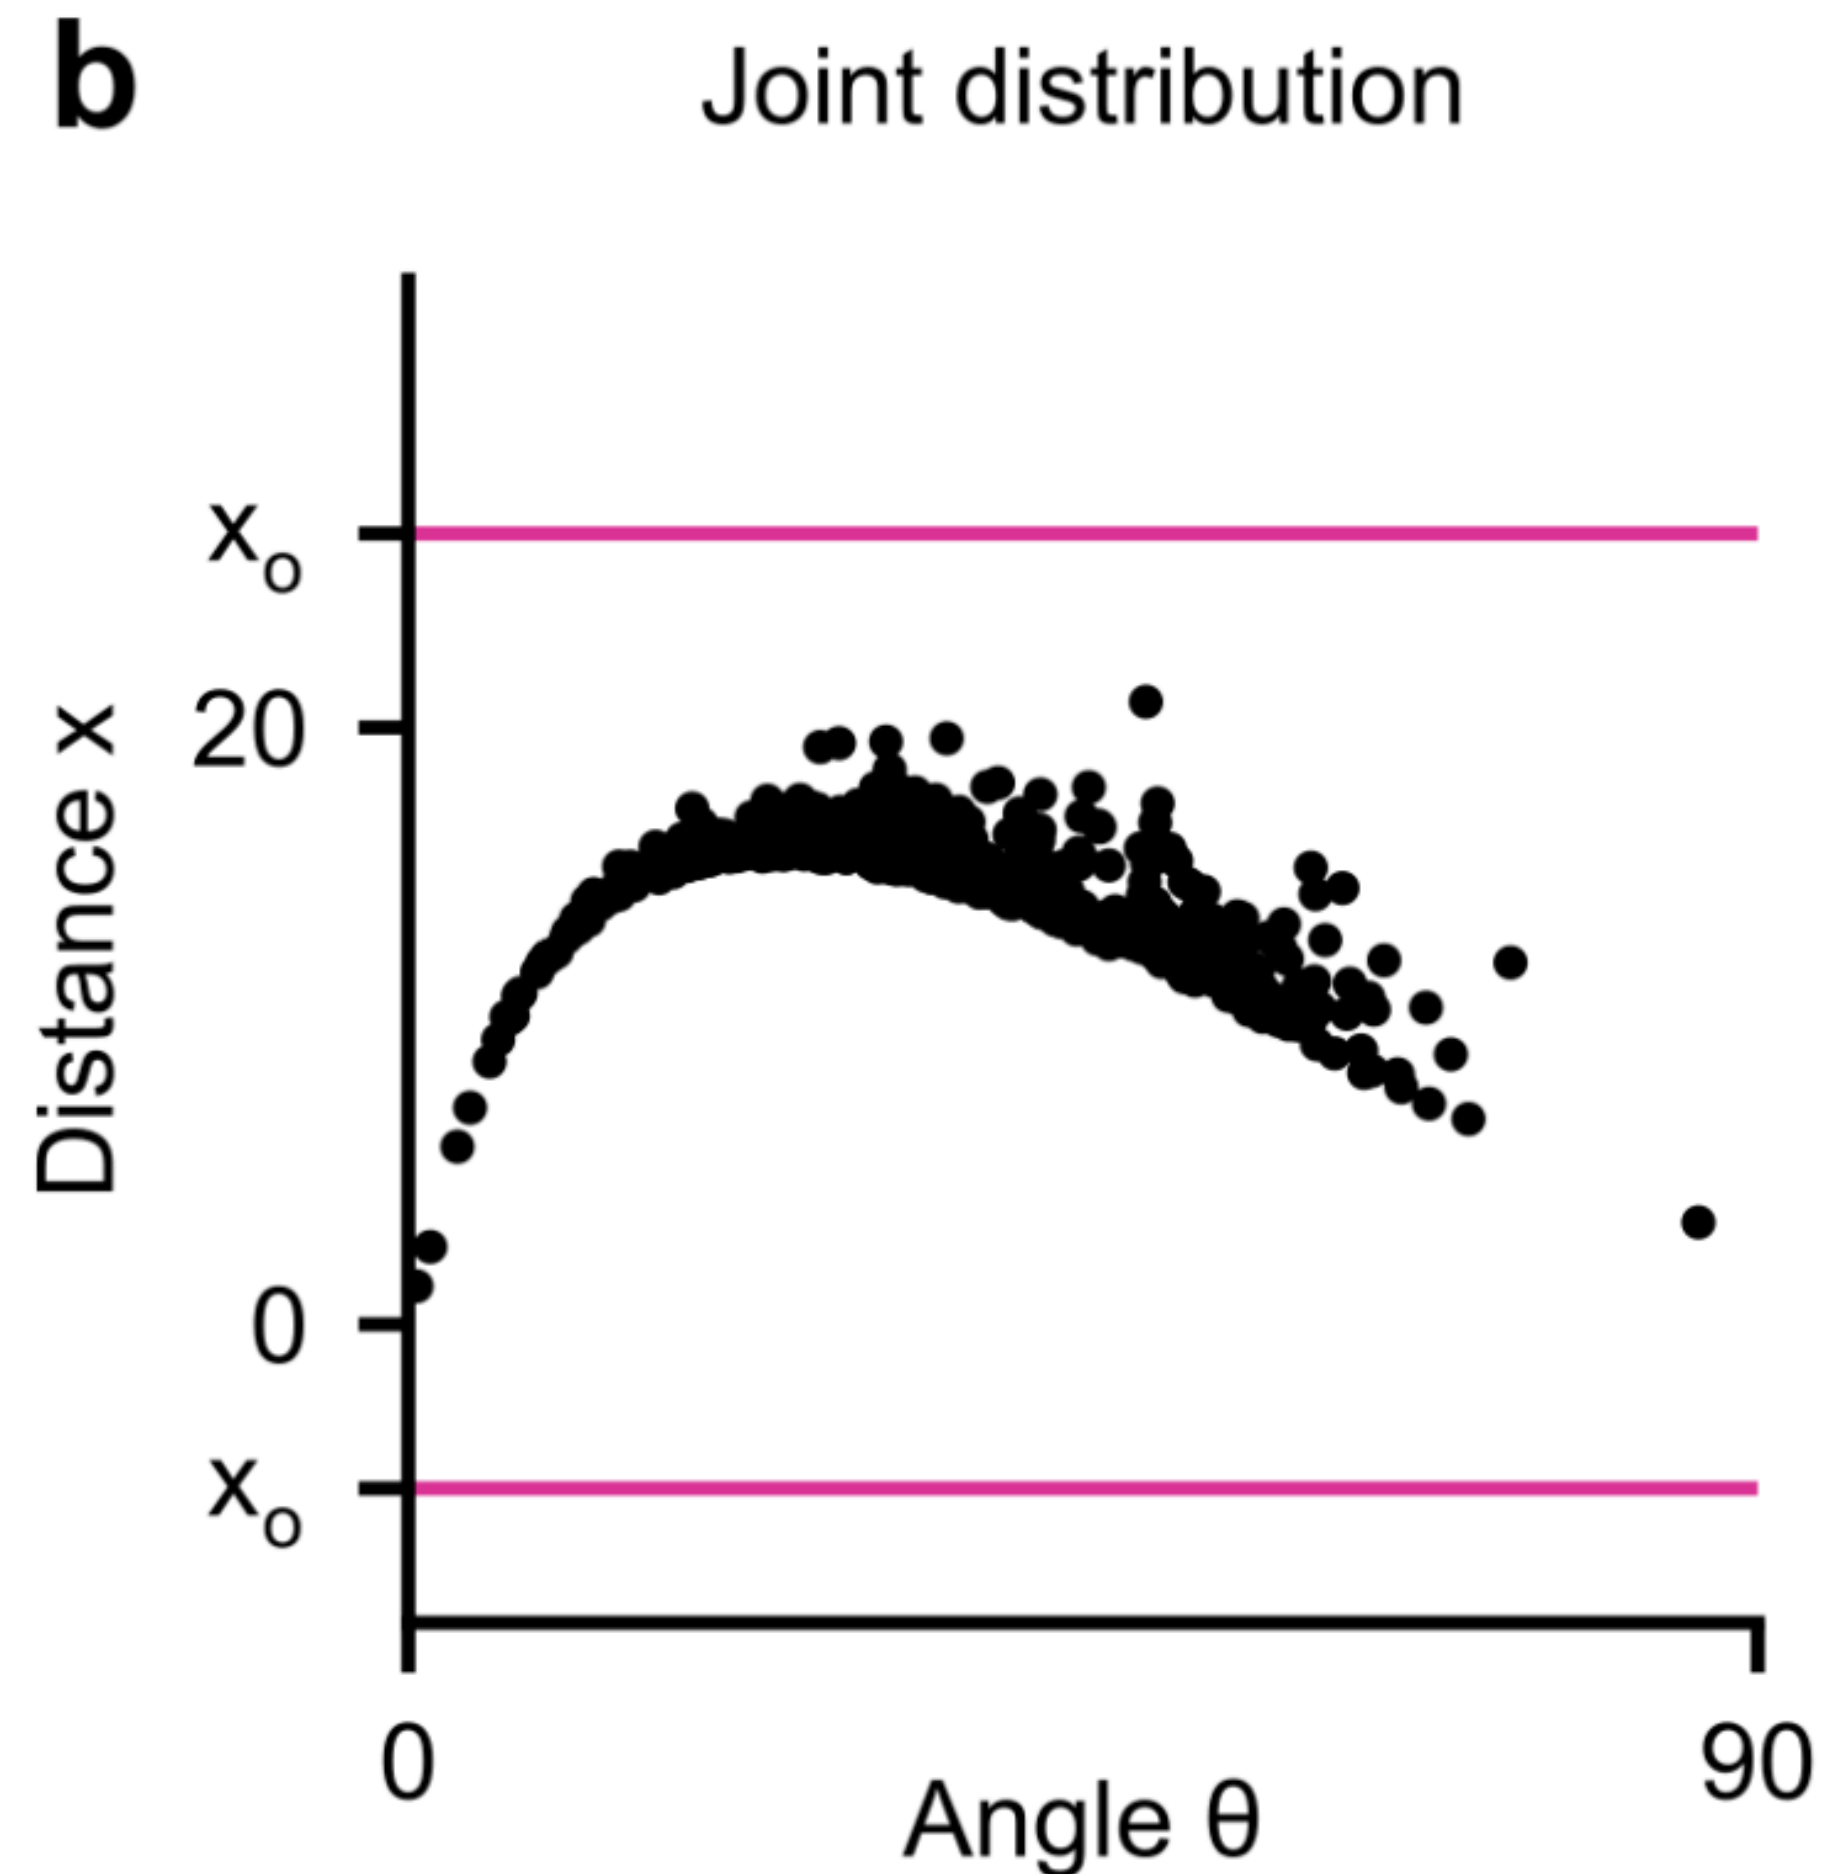
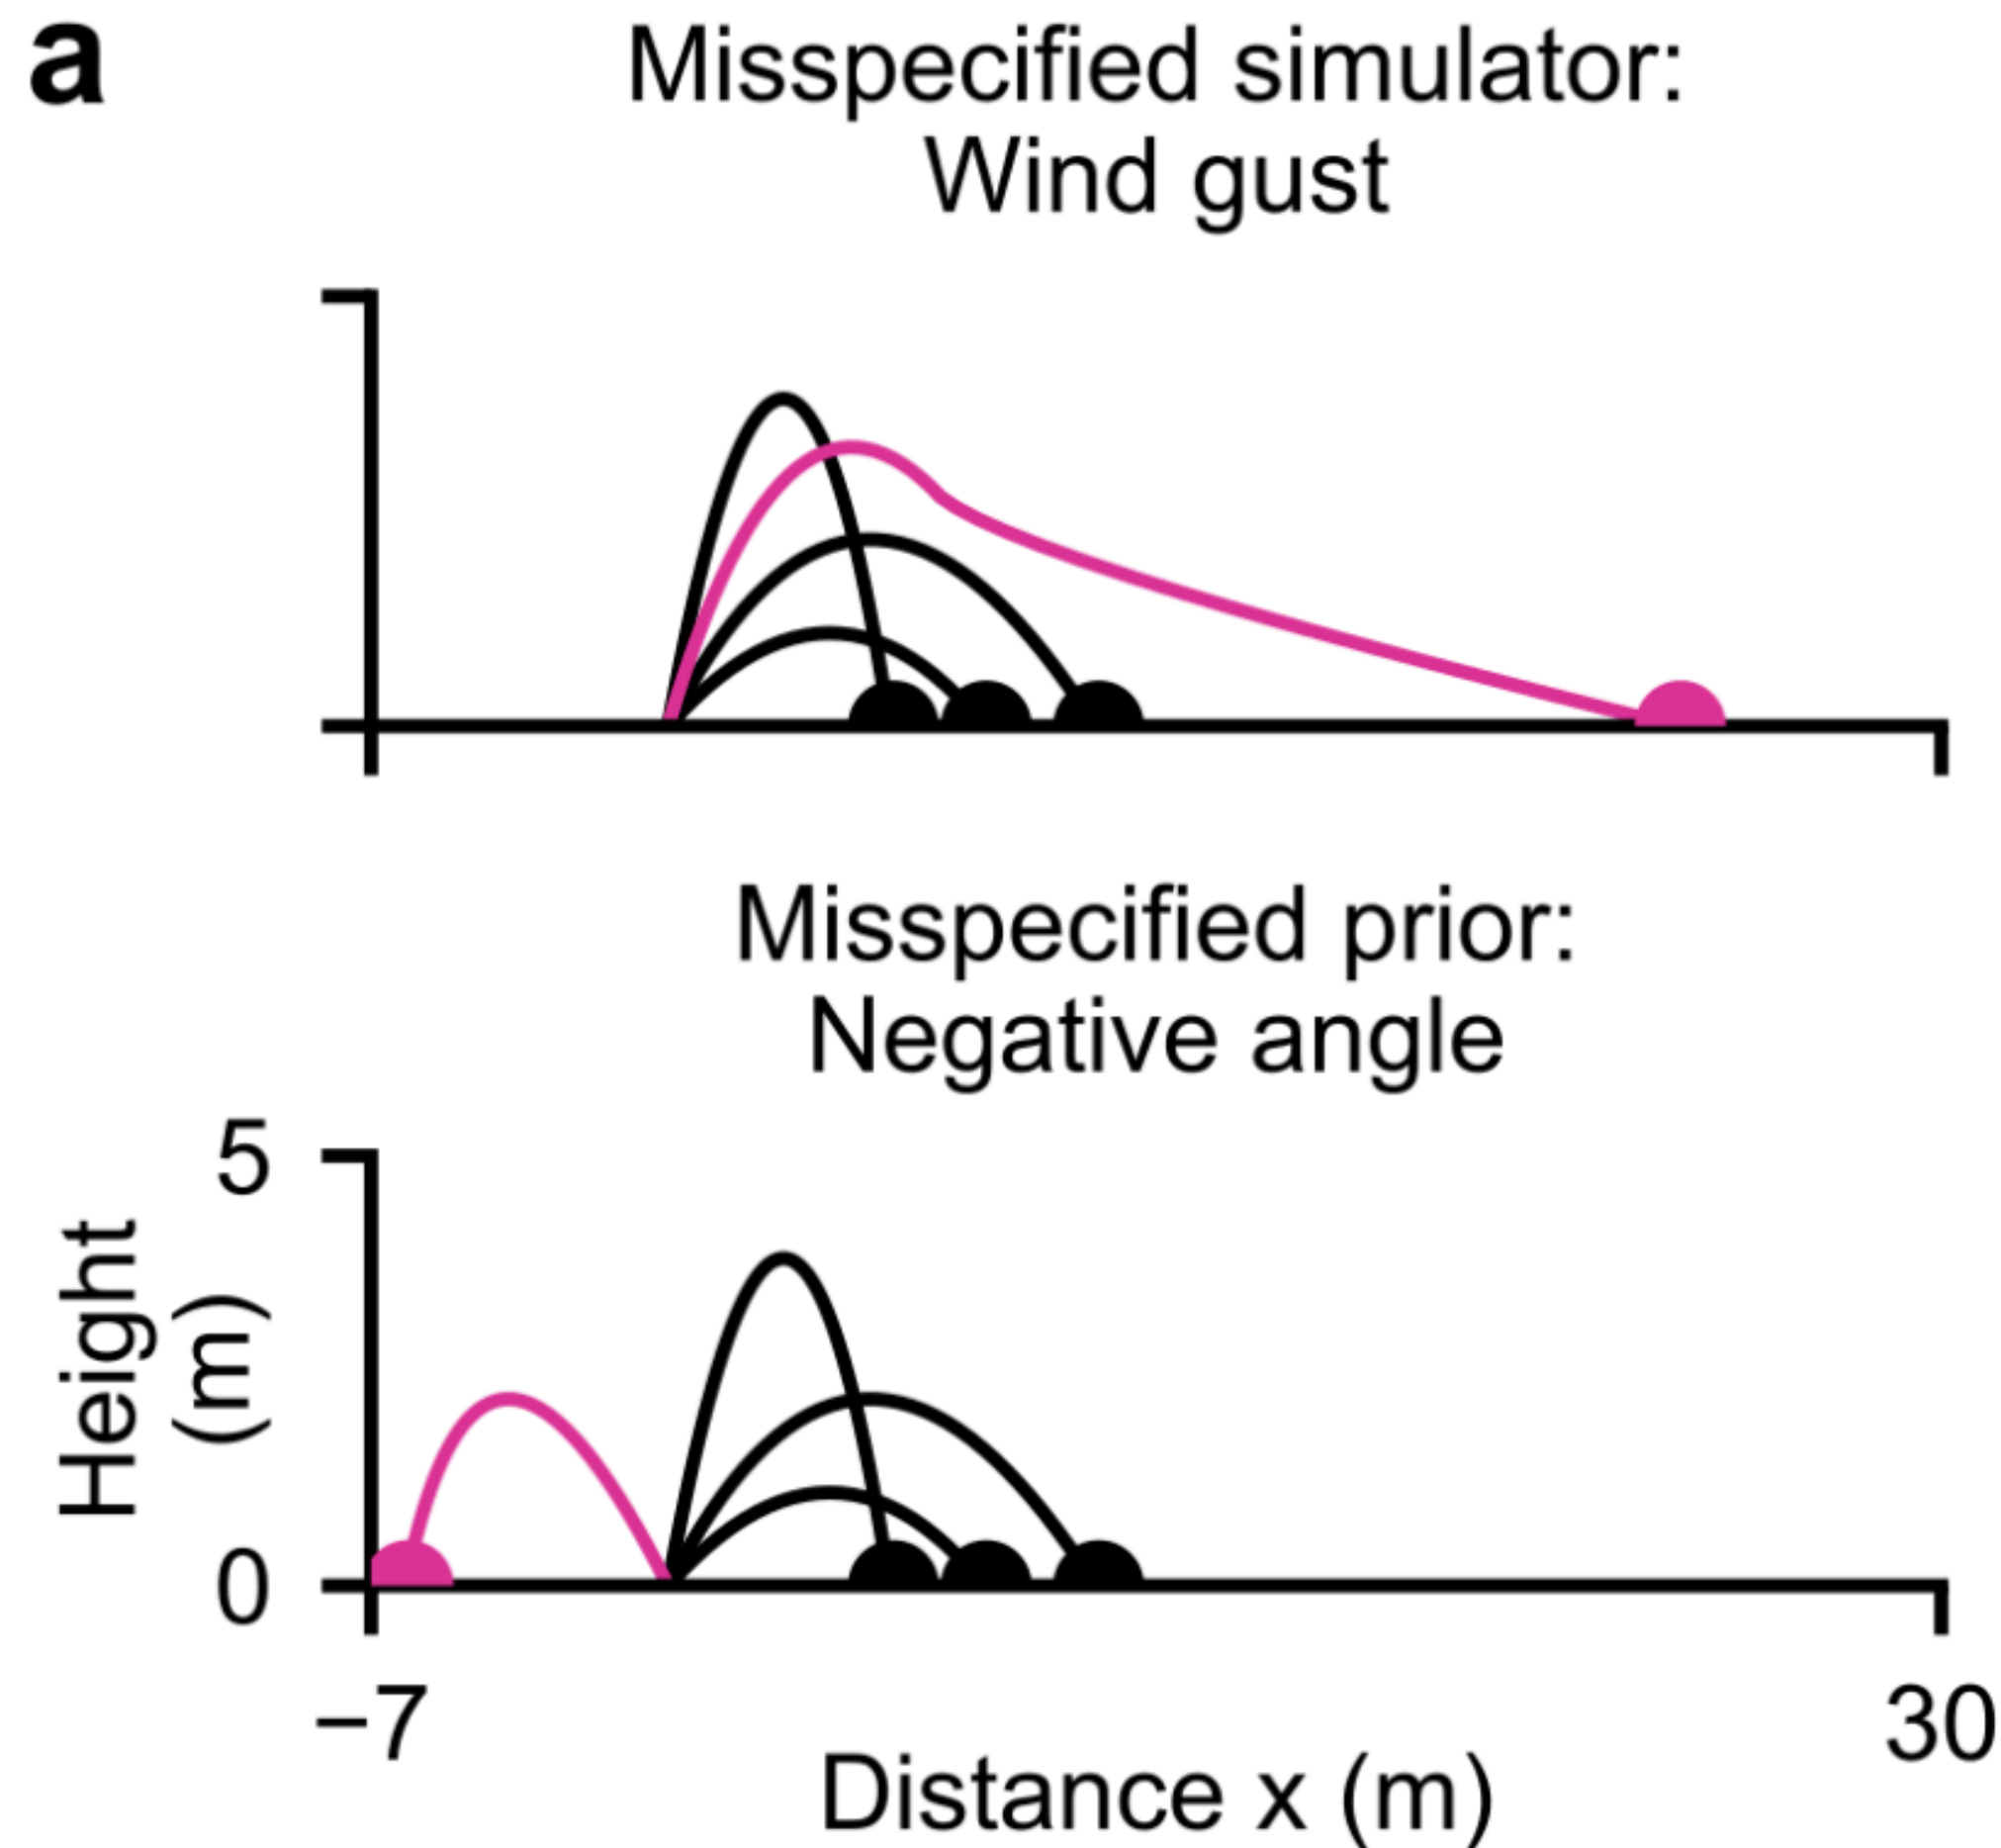
# Inferencia Basada en Simulaciones

## Segunda idea: Metamos redes neuronales! SBI



# Inferencia Basada en Simulaciones

Modelo mal especificado: las NNs no hacen magia!



<https://arxiv.org/abs/2508.12939>

# Inferencia Basada en Simulaciones

## Variantes

Podríamos estar interesados en dos problemas distintos

### Forward

$$\theta \rightarrow x$$

Los parámetros físicos producen observaciones

$$p(x | \theta)$$

*Verosimilitud*

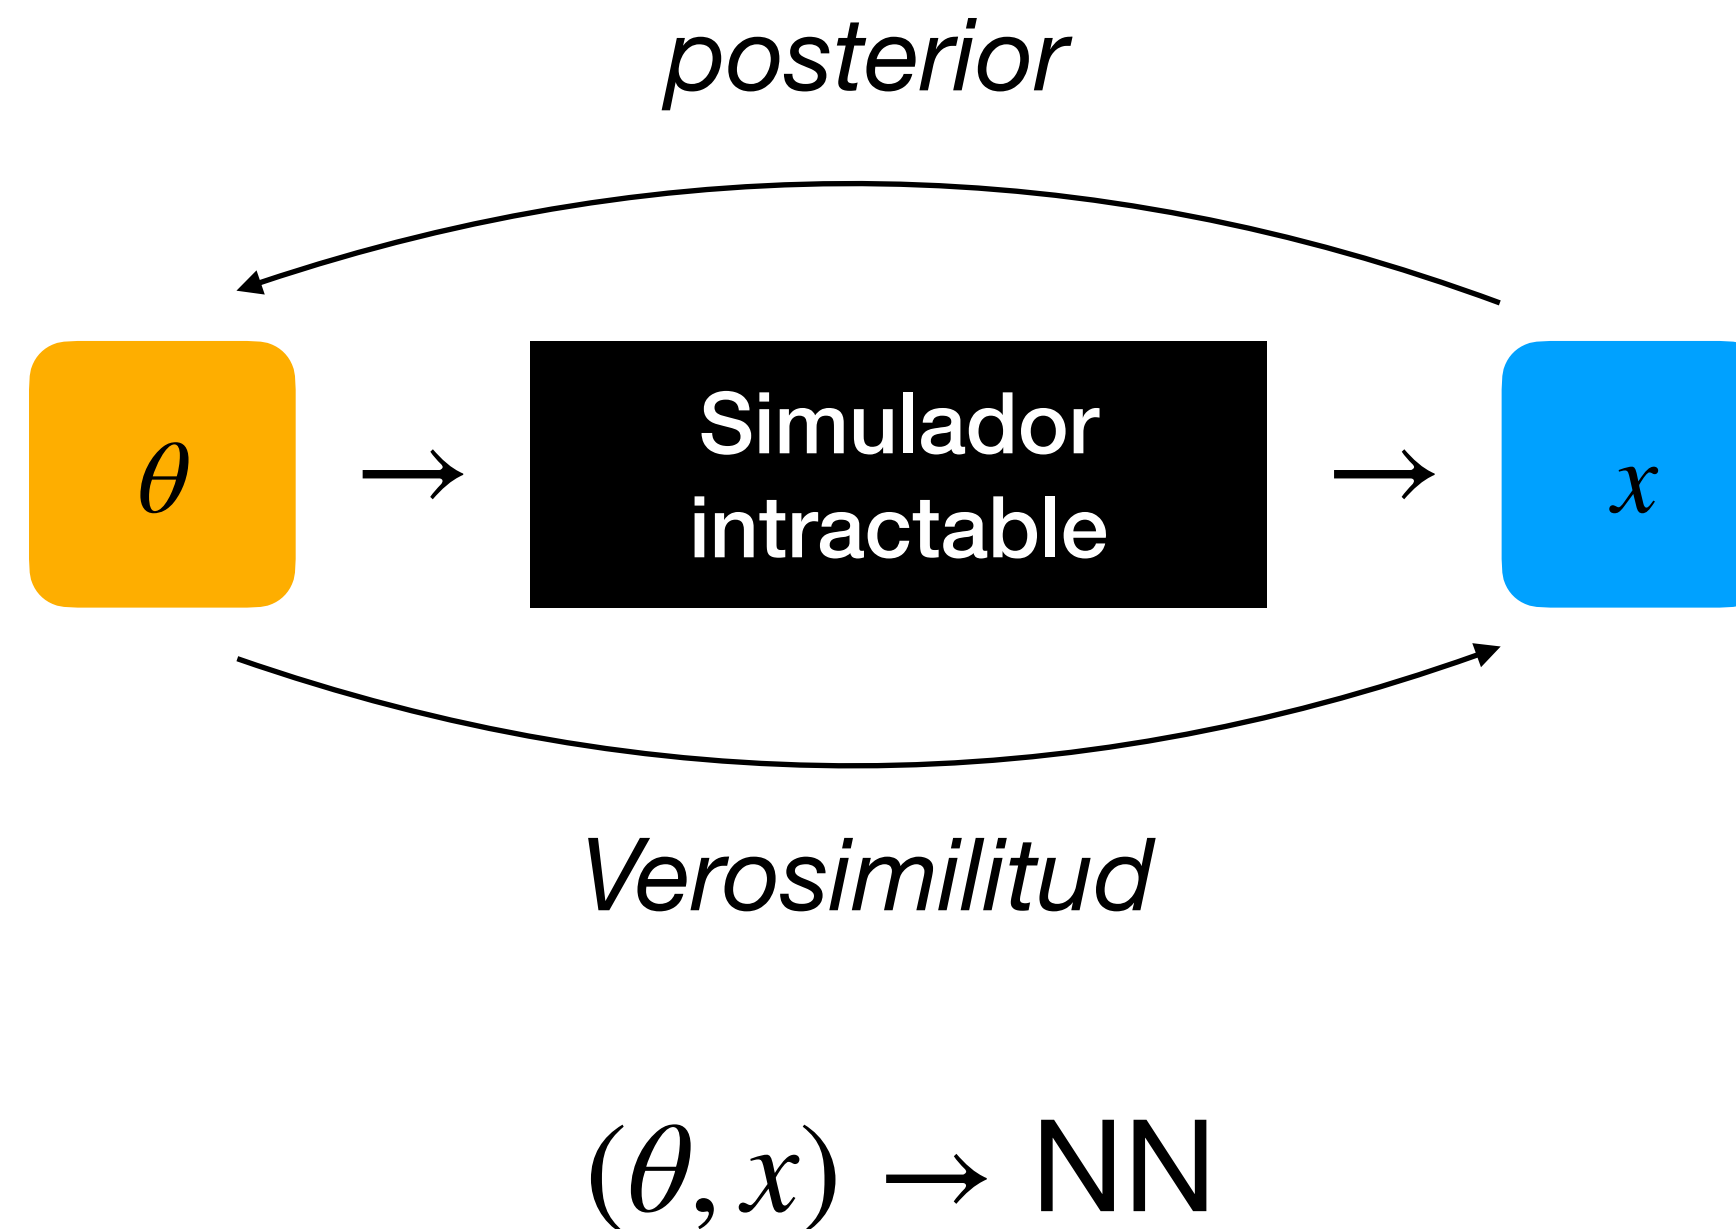
### Inverse

$$x \rightarrow \theta$$

Los datos nos permiten estimar los parámetros físicos

$$p(\theta | x)$$

*posterior*



Usamos al simulador como un modelo generativo que genera pares  $(\theta, x)$

# Inferencia Basada en Simulaciones

## *Neural Posterior Estimation (NPE)*

La red neuronal aprende la distribución posterior  $p(\theta | x)$  a partir de los datos generados mediante simulaciones  $(\theta, x) = \{(\theta_i, x_i)\}_{i=1, \dots, N}$  utilizando  $\theta$  o alguna función de  $\theta$ ,  $g(\theta)$  como características de entrada y  $x$  o alguna función de  $x$ ,  $f(x)$  como target.

Los  $\theta$  fueron generados maestreando de alguna distribución a priori poco informativa (si no se cuenta con información previa)

Queremos aprender  $p(\theta | x)$  a partir de  $(\theta, x)$ ...

Los **Normalizing Flows** aparecen como solución inmediata!

Los MDN también son excelentes opciones

# Inferencia Basada en Simulaciones

## Modelo probabilístico de fondo

De los modelos probabilísticos que vimos, por qué los NFs?

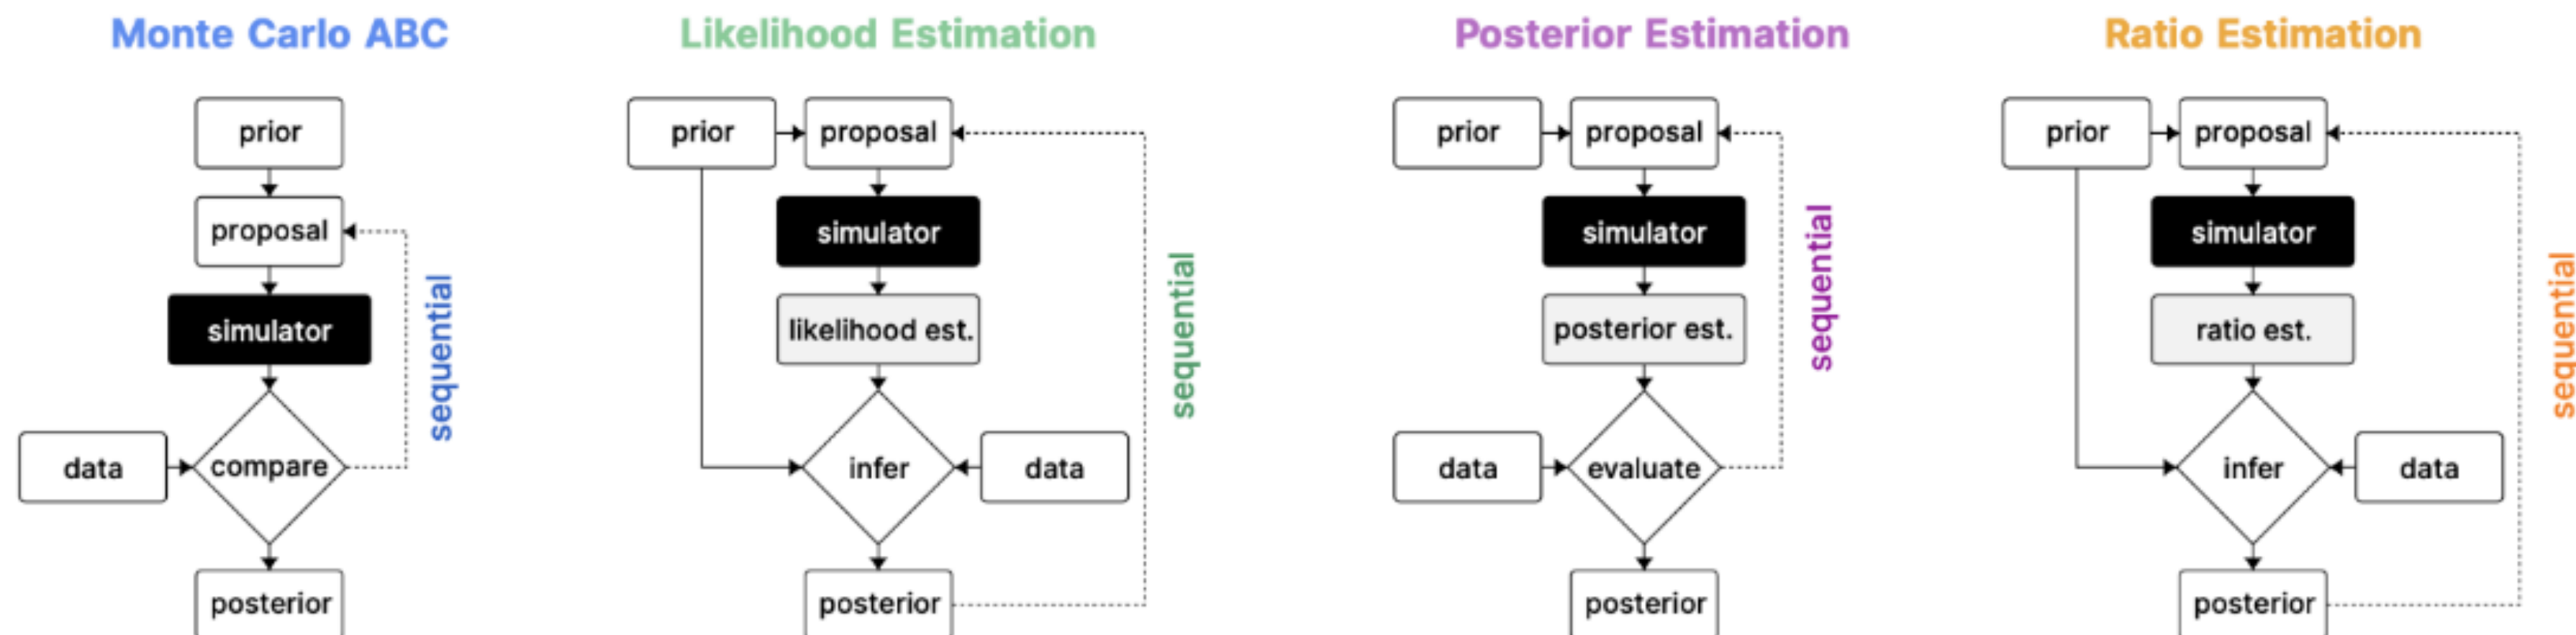
- No sólo queremos generar muestras plausibles de la posterior, queremos representar la probabilidad condicional y evaluarla numéricamente. En NFs aprendíamos la distribución directamente, sin método variaciones.
- Simples de entrenar
- Permite muestras, evaluar densidad, entrenar por MLE, estimar posterior normalizada.
- Expresivos

# Inferencia Basada en Simulaciones

## NPE, NLE, NRE?

Podríamos tener distintos objetivos:

- Estimar la distribución posterior (Neural Posterior Estimation, NPE)  $p(\theta | x)$
- Estimar la verosimilitud (Neural Likelihood Estimation, NLE)  $p(x | \theta)$
- Estimar un cociente entre verosimilitudes (Neural Ratio Estimation, NRE)  $\frac{p(x | \theta)}{p(x)}$



# Inferencia Basada en Simulaciones

## NPE - Estimación neuronal de la posterior

objetivo  $p(\theta | x)$

Amortizar es compartir parámetros entre distintos modelos para producir distintas predicciones

$$q_{\phi}(\theta | x) \approx p(\theta | x)$$

Generamos simulaciones  $(\theta_i, x_i) \sim p(\theta)p(x | \theta) = p(\theta, x)$

Entrenamos  $\max_{\phi} \sum_i \log q_{\phi}(\theta_i | x_i)$   $\mathcal{L}_{NPE}(\phi) = \mathbb{E}_{p(\theta, x)} \left[ \log q_{\phi}(\theta | x) \right]$

Equivale a minimizar  $KL(p(\theta | x) || q_{\phi}(\theta | x))$  promediado sobre  $p(x)$

[https://github.com/mlcolab/sbi-workshop/blob/main/slides/2\\_2\\_snpe.ipynb](https://github.com/mlcolab/sbi-workshop/blob/main/slides/2_2_snpe.ipynb)

# Inferencia Basada en Simulaciones

## NPE - inferencia

Una vez entrenado

$$q_{\phi}^*(\theta | x) \approx p(\theta | x)$$

Por lo tanto  $q_{\phi}^*(\theta | x_o)$  es directamente el posterior aproximado.

### **Ventajas:**

- Inferencia rápida
- Muestreo directo

### **Desventajas:**

- Difícil en dimensiones altas de  $\theta$
- Condicionado en  $x$

Resuelve problema **inverso**

$$x \rightarrow \theta$$

# Inferencia Basada en Simulaciones

## NLE - Estimation neuronal de la verosimilitud

objetivo  $p(\theta | x)$

En NLE aproximamos la verosimilitud primero

$$q_{\phi}(x | \theta) \approx p(x | \theta)$$

Generamos simulaciones  $(\theta_i, x_i) \sim p(\theta)p(x | \theta) = p(\theta, x)$

Entrenamos  $\max_{\phi} \sum_i \log q_{\phi}(x_i | \theta_i)$   $\mathcal{L}_{NLE}(\phi) = \mathbb{E}_{p(\theta, x)} \left[ \log q_{\phi}(x | \theta) \right]$

Equivale a minimizar  $KL(p(x | \theta) || q_{\phi}(x | \theta))$

# Inferencia Basada en Simulaciones

## NLE - inferencia

Una vez entrenado, debemos usar Bayes

$$\hat{p}(\theta | x_o) \propto q_{\phi}^*(x_o | \theta)p(\theta)$$

Es decir que debemos utilizar MCMC, HMC, o algún método de sampleo para estimar la posterior

### **Ventajas:**

- Reutilizable para múltiples priors
- Más estable
- Likelihood explícita

### **Desventajas:**

- Require MCMC posterior
- Costoso en inferencia
- Difícil para alta dimension de  $x$

Resuelve problema **forward**

$$\theta \rightarrow x$$

# Inferencia Basada en Simulaciones

## NRE - Estimation neuronal de la razón

objetivo  $p(\theta | x)$

En NRE aproximamos la razón

$$r(x, \theta) = \frac{p(x | \theta)}{p(x)}$$

Observemos que

$$p(\theta | x) = \frac{p(x | \theta)p(\theta)}{p(x)} = r(x, \theta)p(\theta)$$

# Inferencia Basada en Simulaciones

$$r(x, \theta) = \frac{p(x | \theta)}{p(x)}$$

## NRE - Estimation neuronal de la razón

En NRE transformamos la inferencia en clasificación binaria! Para esto construimos dos distribuciones

**Distribución conjunta**

$$p_1(x, \theta) = p(x, \theta)$$

*Verdadera distribución*

**Producto marginal**

$$p_0(x, \theta) = p(x)p(\theta)$$

*Supuesto independencia*

Generamos  $(x, \theta)$  de ambas distribuciones y entrenamos un clasificador

$$y = \begin{cases} 1 & (x, \theta) \sim p(x, \theta) & (\theta_i, x_i) \\ 0 & (x, \theta) \sim p(x)p(\theta) & (\theta_i, x_j), i \neq j \end{cases}$$

Entrenamos red

$$d_\phi(x, \theta) \approx p(y = 1 | x, \theta)$$

$$\mathcal{L}_{\text{NRE}}(\phi) = \mathbb{E}_{p(x, \theta)}[\log d_\phi(x, \theta)] + \mathbb{E}_{p(x)p(\theta)}[\log(1 - d_\phi(x, \theta))]$$

# Inferencia Basada en Simulaciones

## NRE - Estimation neuronal de la razón

$$d_{\phi}(x, \theta) \approx p(y = 1 | x, \theta)$$

Usando el teorema de Bayes, el clasificador optimo satisface

$$\begin{aligned} d^*(x, \theta) &= \frac{p(x, \theta)}{p(x, \theta) + p(x)p(\theta)} \\ &= \frac{p(x | \theta)p(\theta)}{p(x, \theta) + p(x)p(\theta)} = \frac{p(x | \theta)}{p(x | \theta) + p(x)} \end{aligned}$$

como  $1 - d^* = \frac{p(x)}{p(x | \theta) + p(x)} \implies \frac{d^*}{1 - d^*} = \frac{p(x | \theta)}{p(x)} = r(x, \theta)$

*Chance (Odds)*

Aprendemos qué tan compatible es  $\theta$  con  $x$

# Inferencia Basada en Simulaciones

## NRE - inferencia

Una vez entrenado, debemos usar

$$\hat{p}(\theta | x_o) \propto r_{\phi}^*(x_o, \theta)p(\theta)$$

Nuevamente necesitamos MCMC, HMC, o algún método de sampleo para estimar la posterior

Ventajas:

- Util cuando la verosimilitud es compleja
- Clasificación es más estable
- Dimensionalidad alta

Desventajas:

- Require MCMC posterior
- Depende de los falsos
- Calibración puede ser difícil

# Inferencia Basada en Simulaciones

## Estadísticas de resumen (Summary Statistics)

A veces conviene aprender una transformación o función de los datos

$$x \rightarrow s(x)$$

Donde  $s(x) \in \mathbb{R}^k$  es na representación comprimida de la observación original.


La idea es reemplazar datos complejos  $x$  por características informativas más fáciles de inferir

En vez de aprender  $p(\theta | x)$  aprendemos  $p(\theta | s(x))$

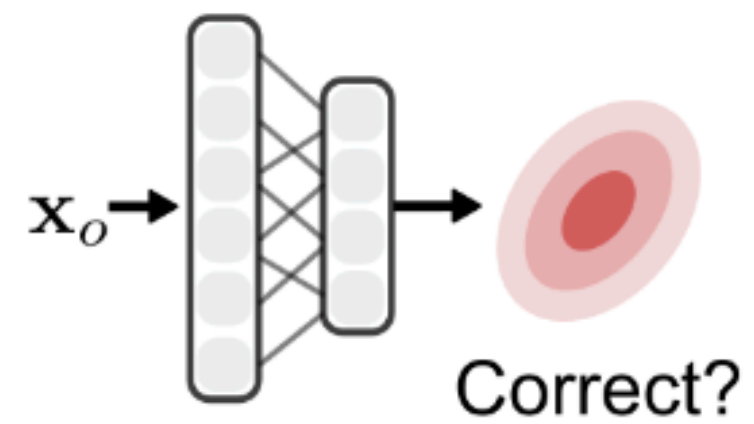
**Interesante:** Podemos aprender las estadísticas de resumen!

# SBI

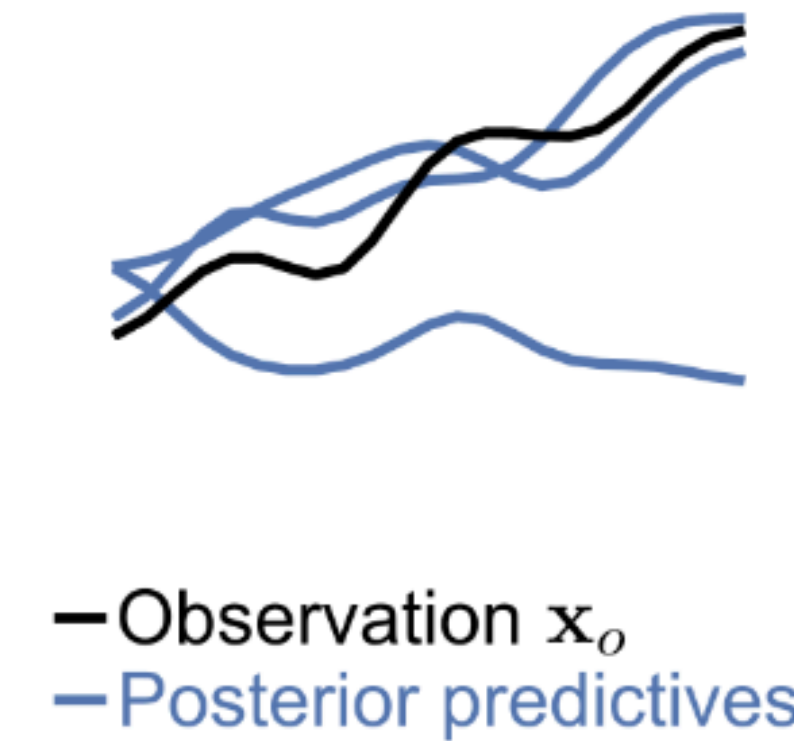
## Consideraciones



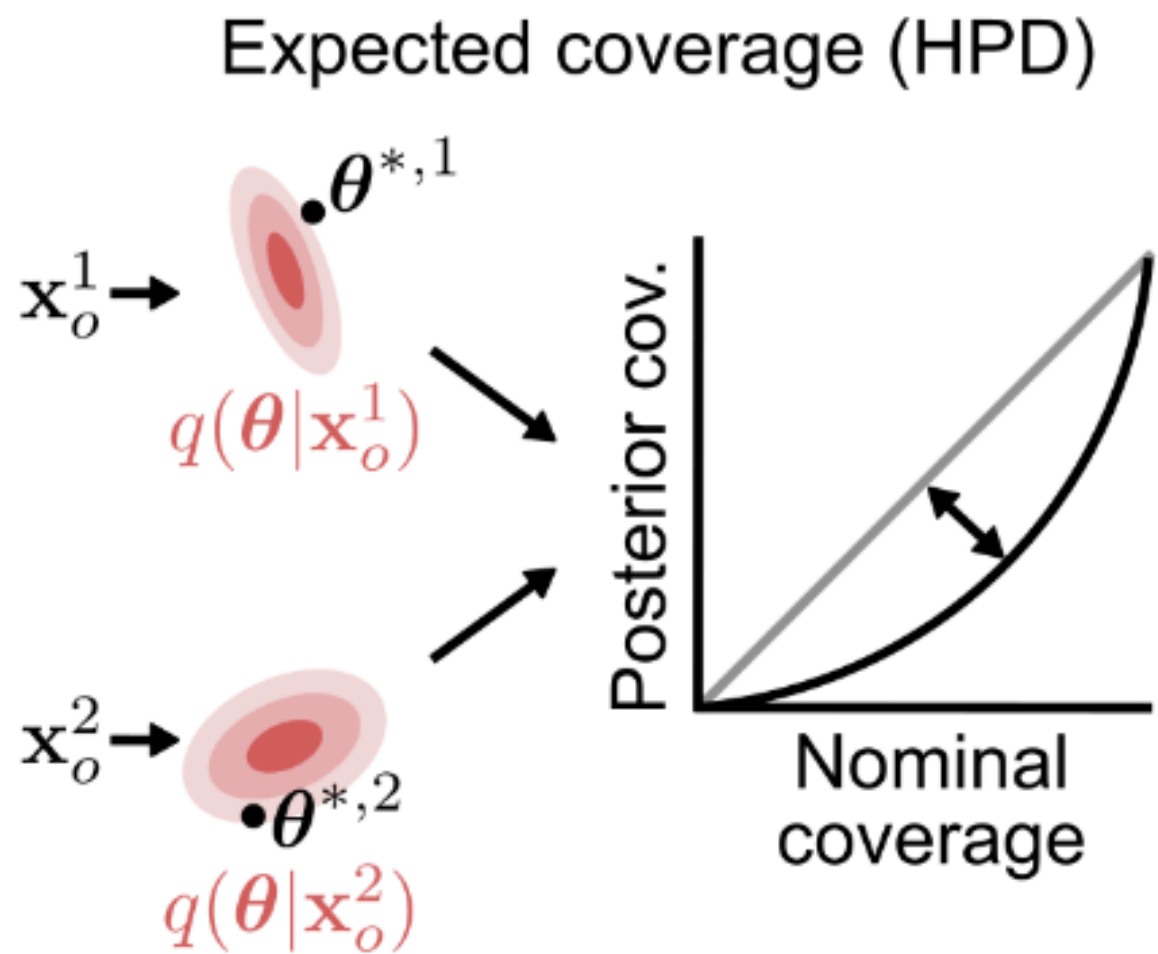
**a** Goal: check posterior correctness



**b** Posterior predictive checks (PPCs)

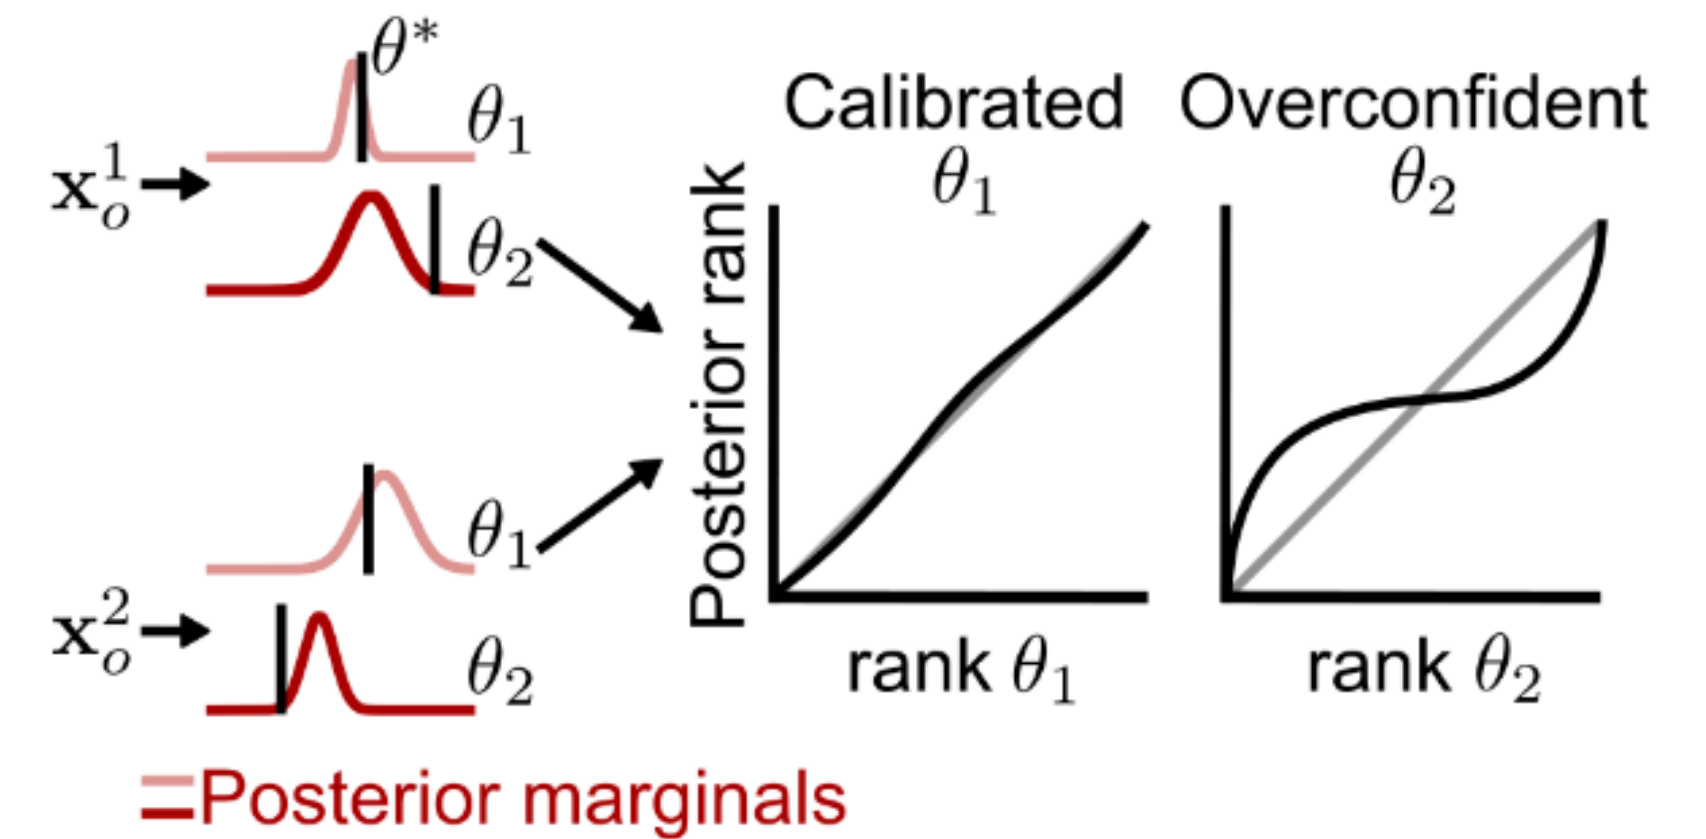


**c**



Global coverage diagnostics

Marginal simulation-based calibration (SBC)



# Inferencia Basada en Simulaciones

## Posterior Predictive Checks (PPC)

Si sampleamos parámetros desde la posterior inferida y volvemos a correr el simulador con ellos, obtenemos datos parecidos a los observados?

$$x^{rep} \sim p(x^{rep} | x_{obs}) \approx \int p(x^{rep} | \theta) q_{\phi}(\theta | x_{obs}) d\theta$$


*Distribución predictiva posterior*

Muestreamos distribución aprendida  $\theta^{(s)} \sim q_{\phi}(\theta | x_o)$


Usamos simulador  $x^{rep,(s)} \sim p(x | \theta^{(s)})$

Comparamos  $x^{rep,(s)}$  con  $x_o$

**a** Goal: check posterior correctness



**b** Posterior predictive checks (PPCs)



— Observation  $x_o$   
— Posterior predictives

# Inferencia Basada en Simulaciones

## Expected coverage

Las regiones de credibilidad de la posterior... ¿contienen al parámetro verdadero con la frecuencia correcta?

### Intervalo de credibilidad

Dado nivel  $\alpha \in (0,1)$


Definimos una *región creíble*  $C_\alpha(x) \in \Theta$ , tal que

Prior:  $\theta \sim p(\theta)$

Simulador:  $x \sim p(x | \theta)$

Posterior aproximada:  $q_\phi(\theta | x)$

$$\int_{C_\alpha(x)} q_\phi(\theta | x) d\theta = \alpha$$



# Inferencia Basada en Simulaciones

## Expected coverage

Imaginemos repetir el experimento muchas veces. Generamos

$$\theta_i \sim p(\theta); x_i \sim p(x | \theta_i)$$


Y luego computamos  $C_\alpha(x_i)$ .

El **expected coverage** a nivel  $\alpha$  es:

$$P(\theta \in C_\alpha(x)), \quad \text{donde } (\theta, x) \sim p(\theta)p(x | \theta).$$

Una posterior calibrada perfectamente satisface

$$P(\theta \in C_\alpha(x)) = \alpha, \quad \forall \alpha \in [0,1]$$



# Inferencia Basada en Simulaciones

## Expected Coverage - Highest Posterior Density (HPD)

Si hacemos marginales, podemos calcular  $C_\alpha(x_i)$  calculando los cuantiles correspondientes (más fácil)


En alta dimension  $\theta \in \mathbb{R}^d$  los cuantiles marginales no definen correctamente una región conjunta. Entonces usamos *High Posterior Density (HPD)*:

$$C_\alpha(x) = \{\theta : q_\phi(\theta | x) > t_\alpha\},$$

Donde  $t_\alpha$  es elegida tal que  $\int_{q_\phi(\theta|x) > t_\alpha} q_\phi(\theta | x) d\theta = \alpha$

### Evaluación MC:

1.  $\theta^{(i)} \sim q_\phi(\theta | x)$
2.  $s_i = q_\phi(\theta^{(i)} | x)$
3.  $s_{(1)} \geq s_{(2)} \geq \dots$
4.  $t_\alpha = \text{quantile}_{1-\alpha}(\{s_i\})$



# Inferencia Basada en Simulaciones

## Expected Coverage - highest Posterior Density (HPD)

Ahora queremos saber si  $\theta_{true} \in C_\alpha(x)$ :

Definimos  $r = P_{q_\phi(\theta|x)}(q_\phi(\theta|x) \geq q_\phi(\theta_{true}|x))$

*HPD Rank*

Cuanta masa tiene densidad mayor que  $\theta_{true}$ ?

Entonces  $\theta_{true} \in C_\alpha(x)$  si  $r < \alpha$

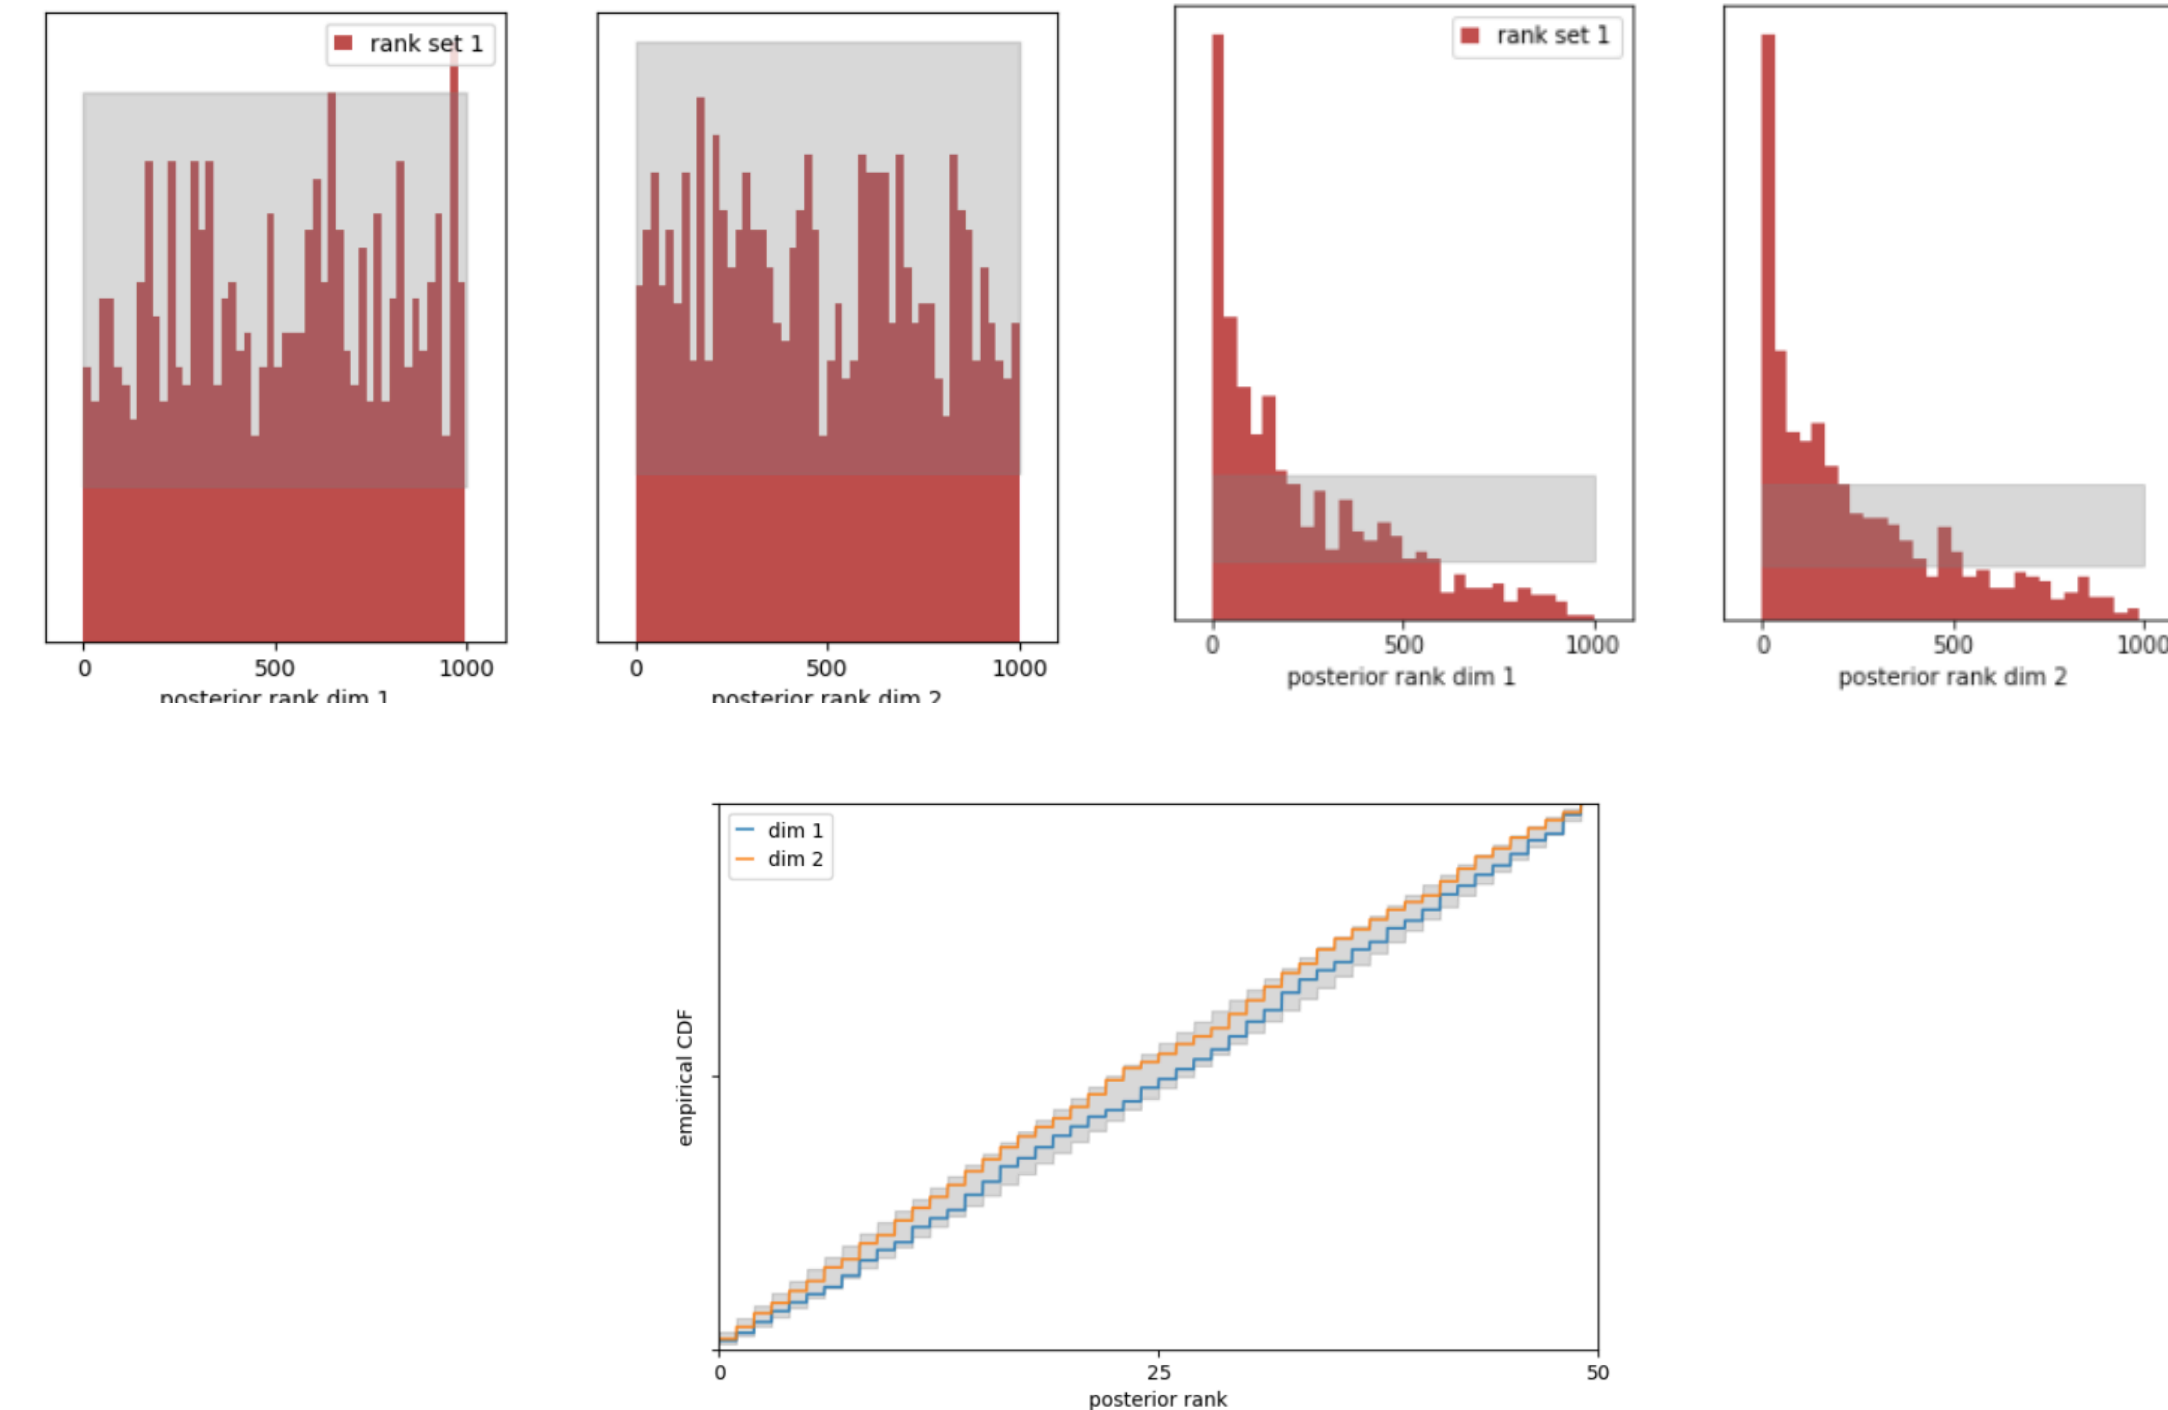
El HPD rank indica qué tan “central” es  $\theta_{true}$  dentro de la posterior: valores pequeños están cerca del modo, valores grandes en las colas.

# Inferencia Basada en Simulaciones

## Simulation Based Calibration (SBC)

Queremos verificar si  $q_\phi(\theta | x)$  está **calibrado**

1. Para  $i = 1, \dots, N$  muestra  $\theta_i \sim p(\theta)$
2. Simular observación  $x_i \sim p(x | \theta_i)$
3. Inferir posterior  $q_\phi(\theta | x)$
4. Muestrear posterior  $\theta_i^{(1)}, \dots, \theta_i^{(M)} \sim q_\phi(\theta | x_i)$
5. Calcular rank  $r_i = \sum_{j=1}^M \mathbf{1}[\theta_i^{(j)} < \theta_i]$



*SBC nos puede decir si no estamos equivocados. Pero no nos dice si estamos en lo correcto. Checkea una condición necesaria pero no suficiente.*

*Si la posterior está correctamente calibrada,  $r_i \sim U[0, M]$*

# Inferencia Basada en Simulaciones

## Qué hacemos finalmente con la posterior aprendida?

Existen varias maneras de resumirla:

- media o mediana

```
mean = samples.mean(0)
std = samples.std(0)
```

- Intervalos de credibilidad

```
low = samples.quantile(0.025, dim=0)
high = samples.quantile(0.975, dim=0)
```

- Correlaciones

- Posteriores marginales

- MAP:  $\theta_{MAP} = \arg \max p(\theta | x)$

```
samples = posterior.sample((100000,), x=x_o)
log_probs = posterior.log_prob(samples, x=x_o)
map_estimate = samples[log_probs.argmax()]
```

SBI no devuelve un único parámetro óptimo, sino una distribución posterior completa que cuantifica incertidumbre, degeneraciones y multimodalidad.

```
from sbi.analysis import pairplot
pairplot(samples)
```

