

Aprendizaje profundo basado en la física

Semana 7: Cuantificación de incertidumbre

Docente: José I. Robledo - 21/05/2026

Cuantificación de incertidumbre

Introducción

- La mayoría de los modelos de aprendizaje automático producen predicciones puntuales.
- No suele alcanzar con esto, muchas veces necesitamos saber qué tan confiable es la predicción


La **cuantificación de incertidumbre (UQ)** en ML busca medir y representar el grado de confianza de un modelo sobre sus propias salidas



Cuantificación de incertidumbre

Para qué sirve?


- Detectar casos ambiguos
- Abstenerse a decidir
- Pedir intervención humana
- Identificar datos fuera de distribución
- Mejorar calibración
- Priorizar adquisición de datos



Incertidumbres

Incertidumbre aleatoria

- Debida al **azar inherente del sistema**: fenómenos intrínsecamente estocásticos.
- Aunque conozcamos perfectamente el fenómeno, seguirá existiendo variabilidad (intrínseca al proceso).
- Es irreducible (no desaparece con más datos)!
- Asociada al ruido natural
- Se modela probabilísticamente



Incertidumbres

Incertidumbre aleatoria: Ejemplos





- Lanzamiento de un dado: aunque entendamos la física de tirar el dado, el resultado siempre será incierto
- Temperatura corporal: dos personas sanas pueden tener temperaturas distintas
- Sensores: ruido electrónico
- Imágenes borrosas, pueden ser ambiguas incluso para humanos

Incertidumbres

Incertidumbre epistémica

- Proviene de la falta de conocimiento del sistema (ignorancia)
- Reducible (disminuye con más datos o mejor modelo)
- Asociada a desconocimiento estructural



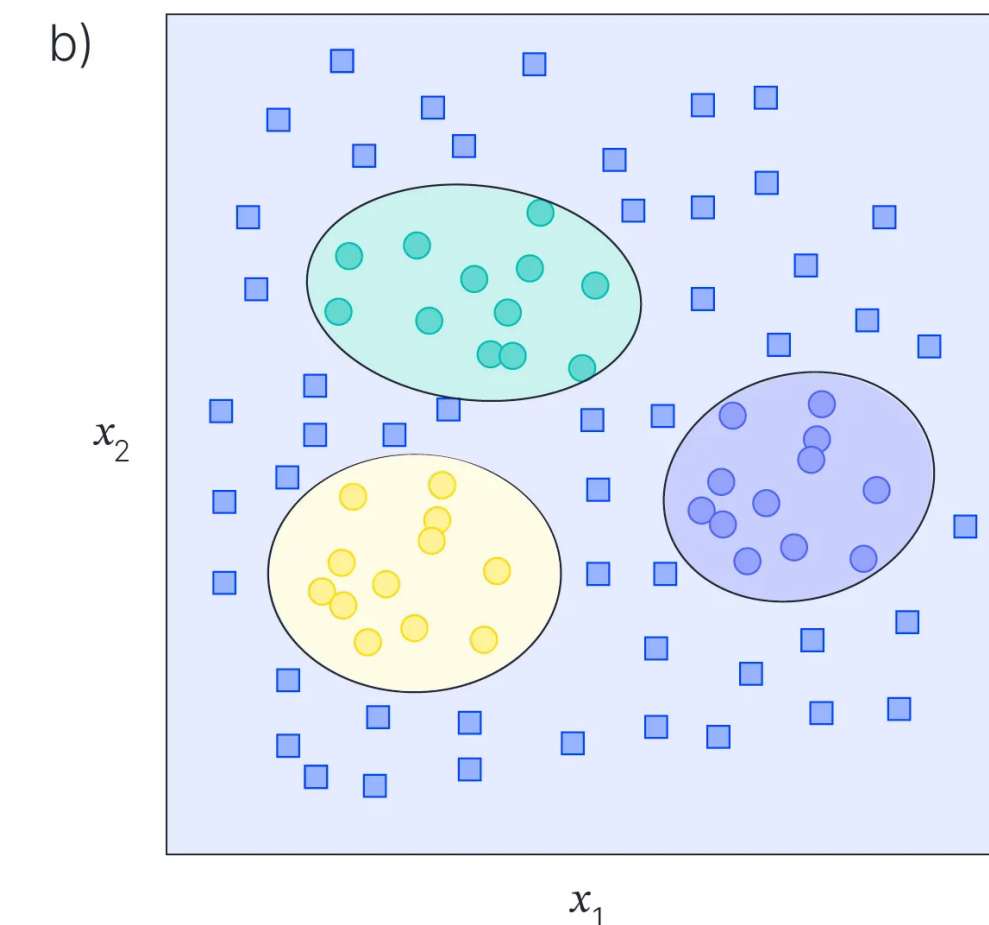

La atmósfera es caótica: aunque tengamos buen modelo, habrá variabilidad
→ Aleatoria

No contamos con suficientes sensores meteorológicos o el modelo es malo
→ *Epistémica*

Incertidumbres

Incertidumbre epistémica: ejemplos

- Si un modelo nunca vio ejemplos de cierta población, tendrá alta incertidumbre epistémica
- No saber el efecto de un medicamento nuevo
- Modelo incompleto del clima
- Out Of Distribution (OOD)



Modelos de Cuantificación de incertidumbre (UQ)

Ya vimos algunos! → Modelos probabilísticos: MDN, VAE, SBI

Aleatória

$$p(y | \theta, x)$$

Epistémica

$$p(\theta | D)$$

Lo que veremos:

- Modelos de Ensamblados
- Monte Carlo Dropout
- Redes Neuronales Bayesianas

Modelos de UQ


Ensembles / deep ensembles

Entrenar múltiples modelos independientes y promediar (o votar sobre) los resultados tiene mejor capacidad predictiva y provee de un mecanismo natural de incertidumbre

$$f_1(x), f_2(x), \dots, f_K(x)$$

$$\hat{y} = \frac{1}{K} \sum_{i=1}^K f_i(x)$$

$$\hat{Var} = \frac{1}{K} \sum_{i=1}^K (f_i(x) - \hat{y})^2$$



Simple, robusto, buen rendimiento

La dispersión entre modelos aproxima incertidumbre epistémica.

Los ensembles funcionan porque distintos modelos representan distintas hipótesis plausibles dadas las observaciones.

<https://arxiv.org/abs/1612.01474>

Modelos de UQ

Monte Carlo Dropout (MCD)

Durante el entrenamiento, podemos apagar neuronas aleatoriamente!


- Reduce overfitting
- Actúa como regularización

~~model.eval()~~

model.train()

Inclusive en evaluación!

Se puede probar que MCD es una aproximación bayesiana de la distribución posterior $p(\theta | D)$



$$\hat{y} = \frac{1}{K} \sum_{i=1}^K f_k(x) \quad \hat{Var} = \frac{1}{K} \sum_{i=1}^K (f_k(x) - \hat{y})^2$$

Redes Neuronales Bayesianas

Del MLP a las BNN

- Las redes neuronales bayesianas extienden a las redes neuronales estándares tratando sus pesos y sesgos como **distribuciones de probabilidad** en vez de valores fijos.
- Esto permite que la red neuronal no sólo prediga un valor sino también cuantifique su incertidumbre.


$$p(W|D) = \frac{p(D|W)p(W)}{p(D)}$$

Inferencia Variacional

$$q_{\phi}(W) \approx p(W|D)$$

$$q_{\phi}(W) = \mathcal{N}(\mu_{\phi}, \sigma_{\phi}^2)$$

$$\mathcal{L}_{ELBO} = \mathbb{E}_{q_{\phi}(W)}[-\log p(D|W)] + KL(q_{\phi}(W) || p(W))$$



Redes Neuronales Bayesianas

Conexión con regularización

En NN clásica

$$\mathcal{L} = \sum_i (y_i - f(x_i; W))^2 + \lambda ||W||^2$$

Interpretación probabilística, suponiendo verosimilitud Gaussiana

$$p(y_i | x_i, W) = \mathcal{N}(f(x_i; W), \sigma_y^2) \implies -\log(D | W) \propto \sum_i (y_i - f(x_i; W))^2$$

Suponemos prior sobre los pesos $p(W) = (0, \sigma_w^2 I)$

Bayes: $p(W | D) \propto p(D | W)p(W) \implies \log p(W | D) = \log p(D | W) + \log(p(W)) + C$

$$MSE + \frac{1}{2\sigma_w^2} ||W||^2$$

Redes Neuronales Bayesianas

BNN probabilística!

Combinamos incertidumbre epistémica con aleatoria en la misma red

BNN

$$W \sim q_{\phi}(W)$$

$$y = f(x_i; W)$$

BNN probabilísticas

$$W \sim q_{\phi}(W)$$

$$y = \mathcal{N}(\mu(x), \sigma^2(x))$$

epistémica


aleatoria

La red produce $(\mu(x), \sigma(x))$

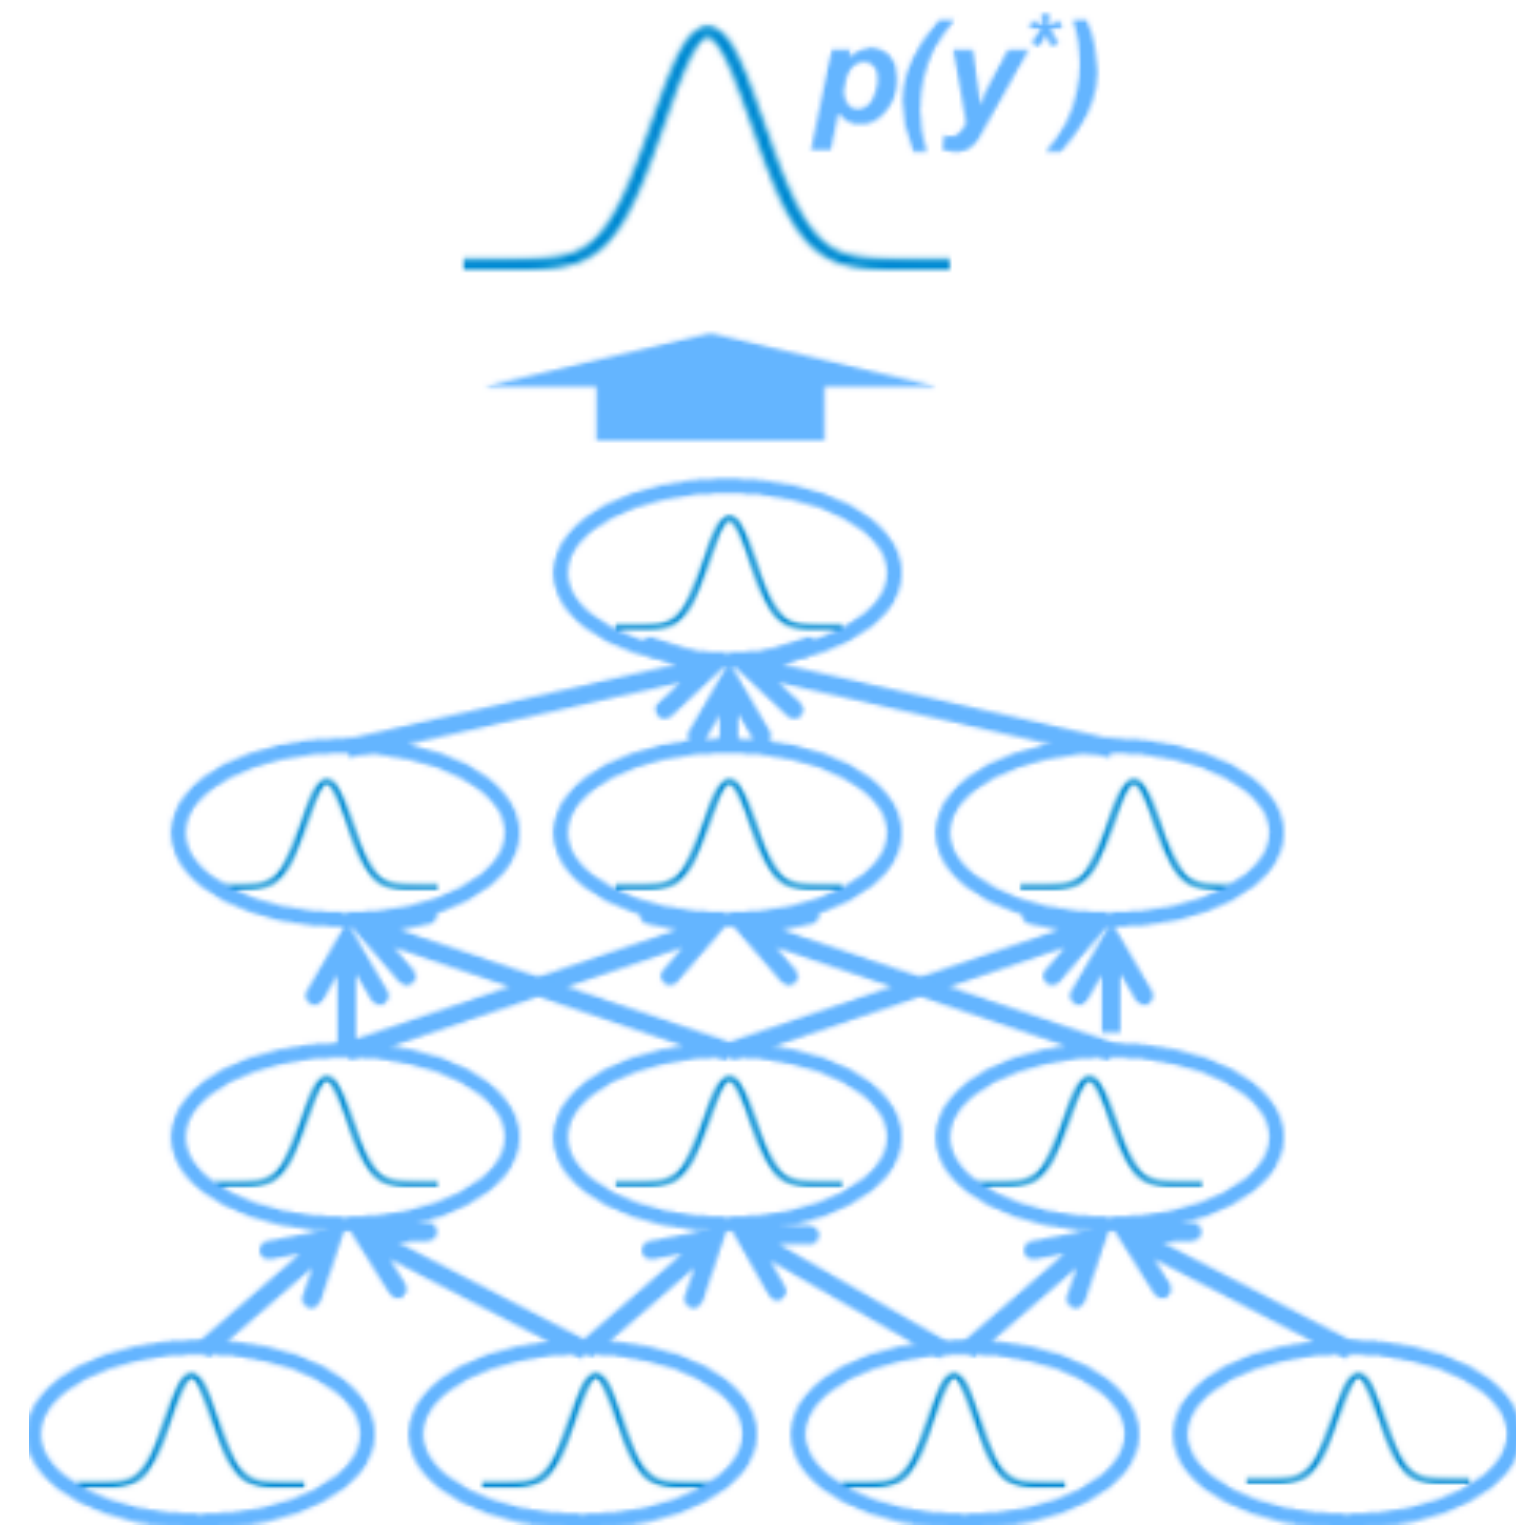
$$(\mu(x_i), \sigma(x_i)) = f(x_i; W)$$

$$\mathbb{E}[\sigma^2(x)] \rightarrow \textit{aleatoria}$$

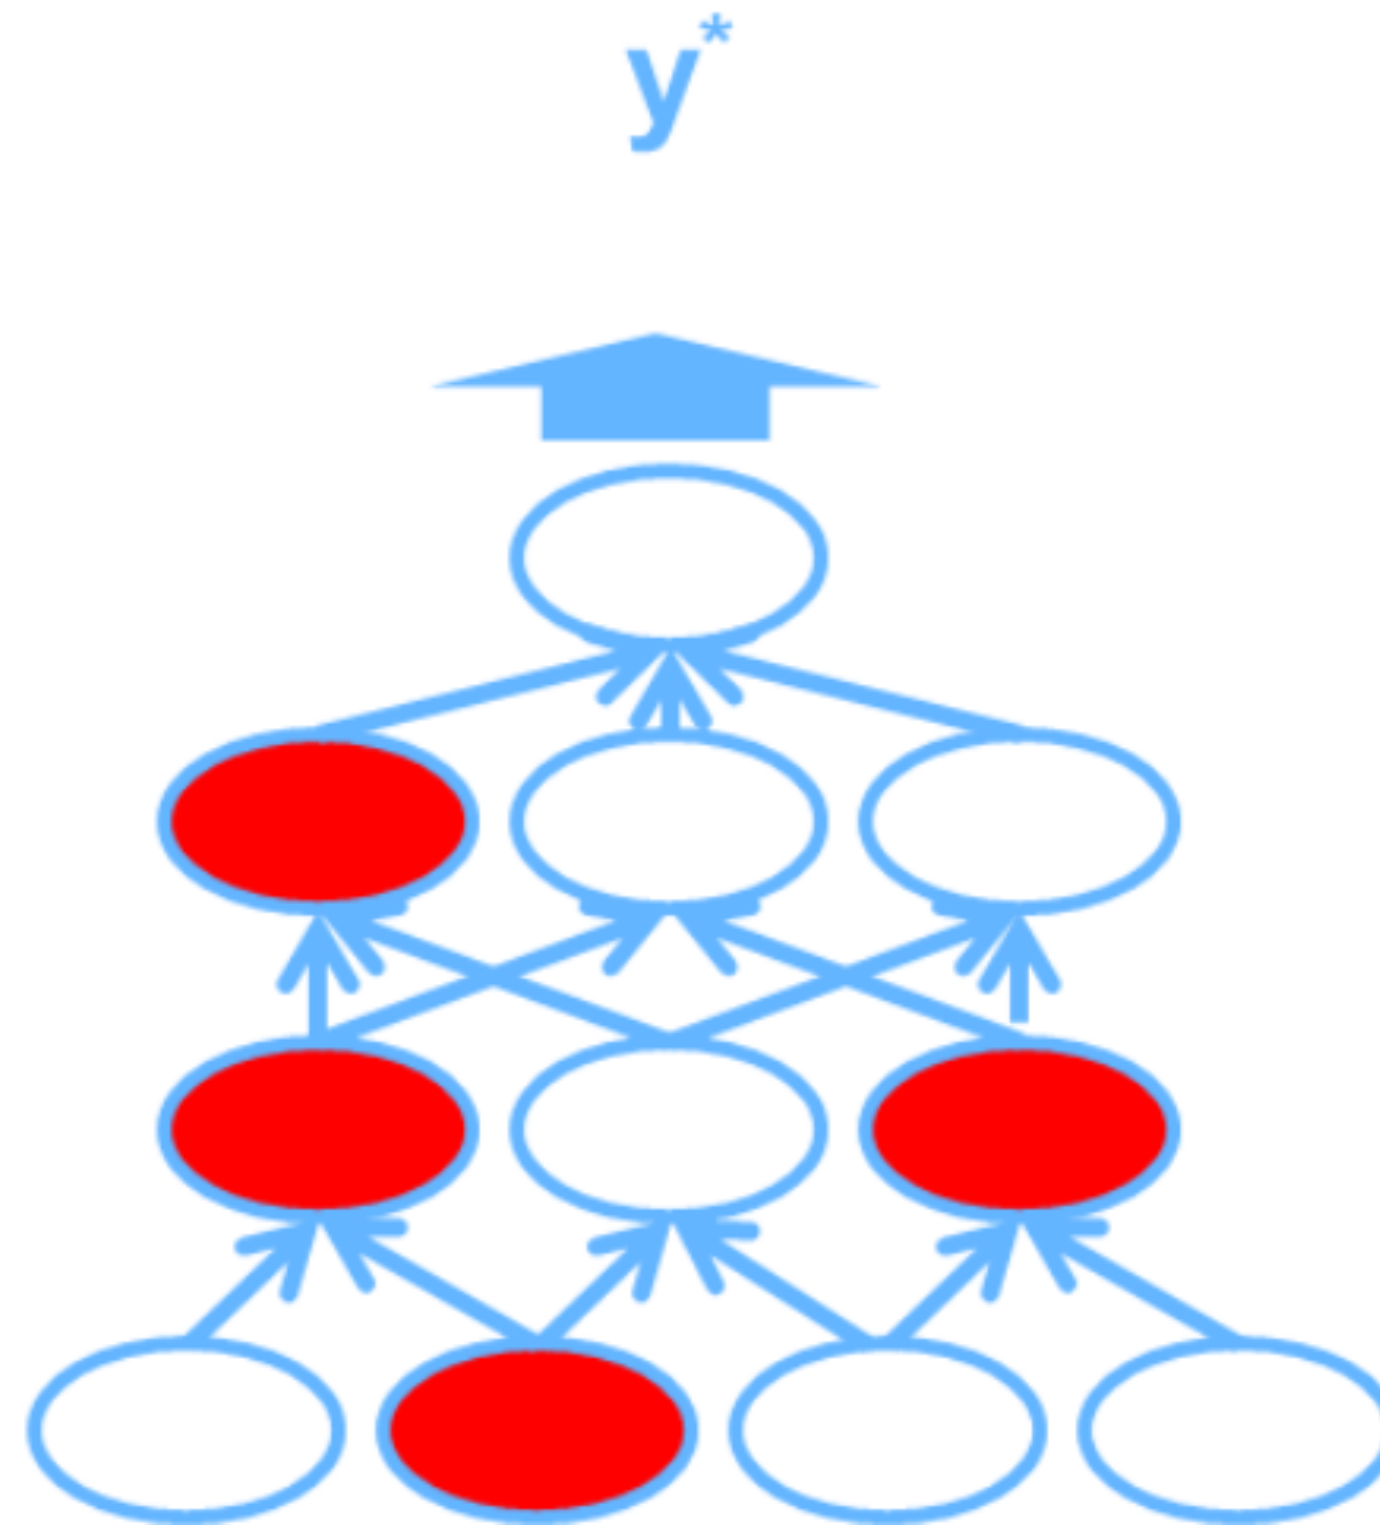
$$\text{Var}[\mu(x)] \rightarrow \textit{epistémica}$$



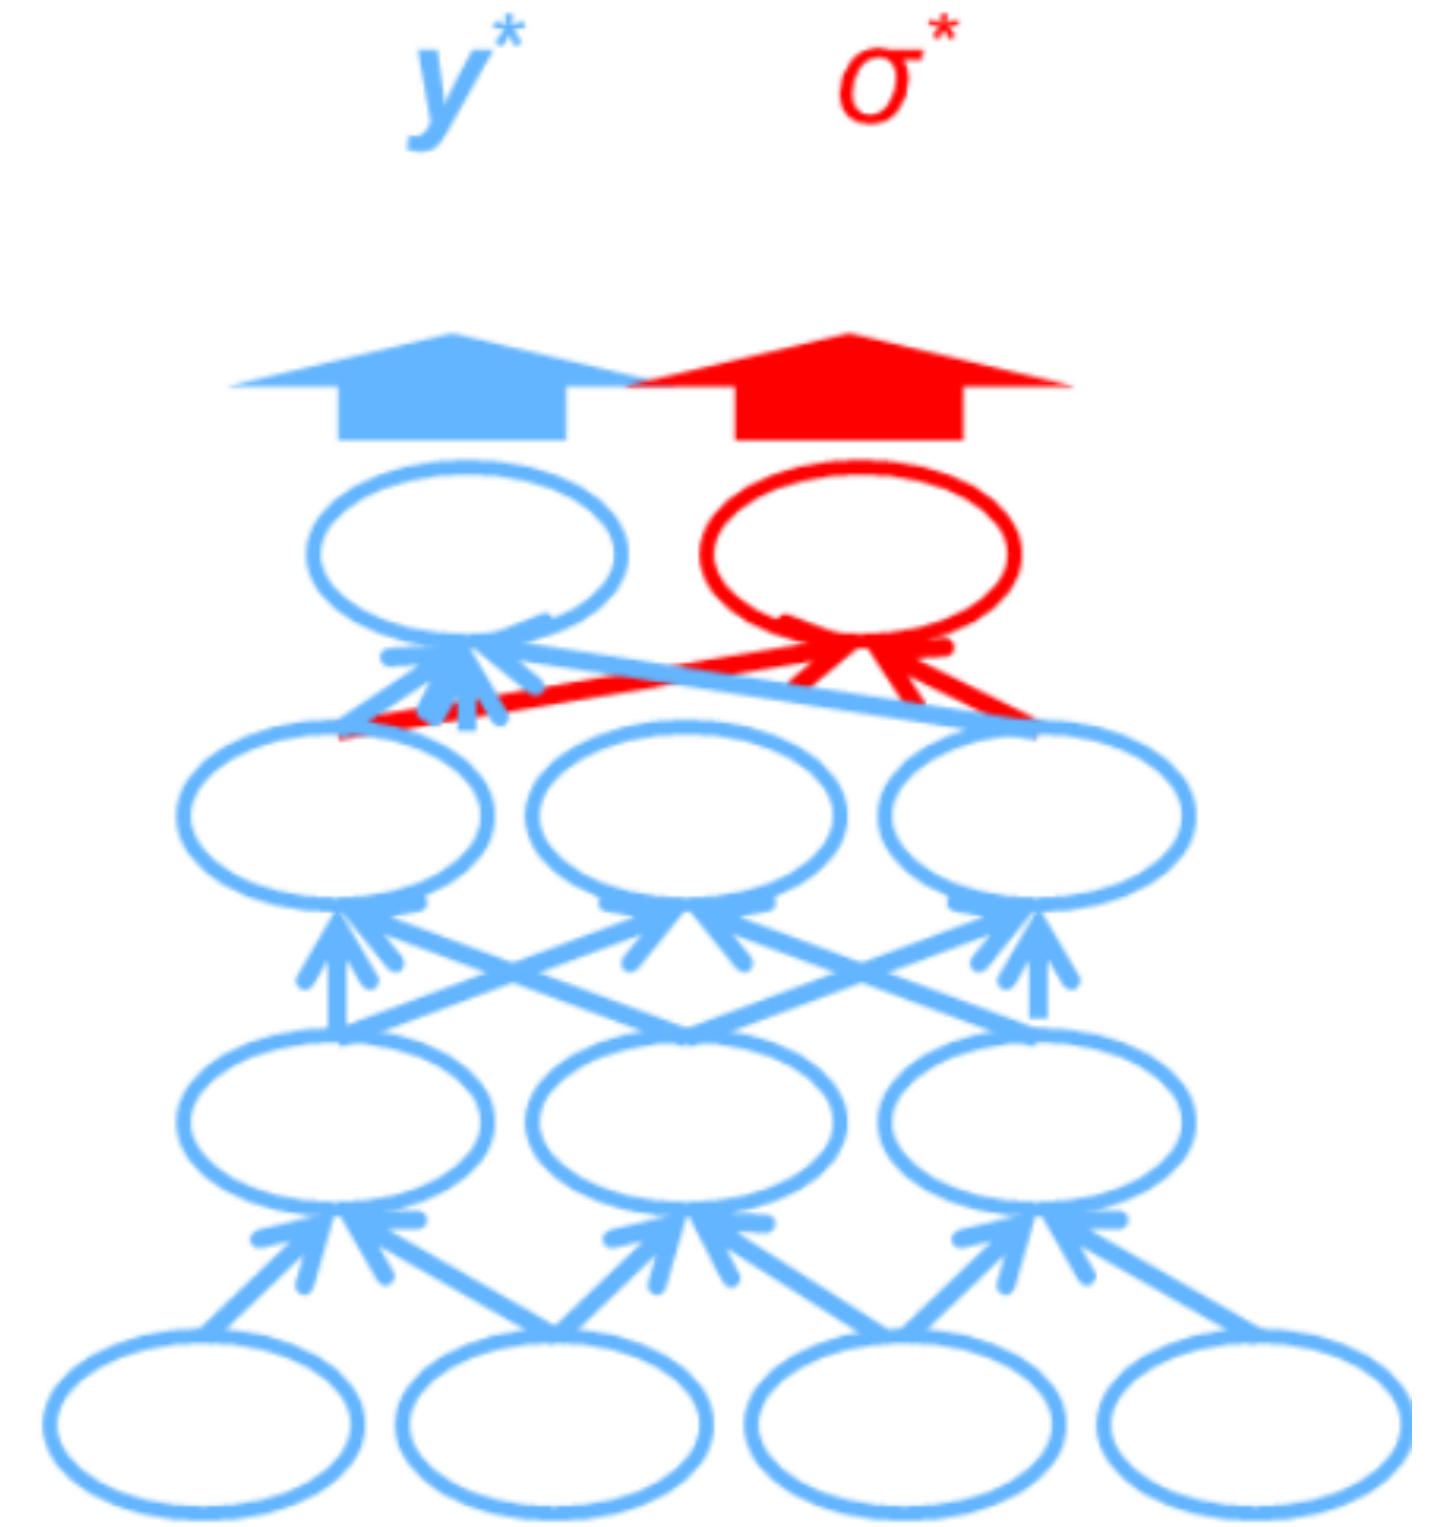
Comparación



Bayesian Neural Nets



MC Dropout



Probabilistic Models