

CLASIFICADOR BAYESIANO INGENUO (NAIVE BAYES)

Teorema de Bayes:

$$P(A|B) = \frac{P(B|A) \cdot P(A)}{P(B)}$$

- Demostración:

$$P(A \cap B) = P(A) \cdot P(B|A) = P(B) P(A|B)$$

$$P(A|B) = \frac{P(A) \cdot P(B|A)}{P(B)}$$

Causas: A_1, \dots, A_n

Suceso: B

VEROSIMILITUD

Sucede B : ¿Prueba de que la causa sea A_k ? A PRIORI

A POSTERIORI

$$P(A_k|B) = \frac{P(B|A_k) P(A_k)}{P(B)} = \frac{P(B|A_k) P(A_k)}{\sum_{i=1}^n P(B|A_i) \cdot P(A_i)}$$

$$P(B) = \sum_{i=1}^n P(B|A_i) \cdot P(A_i)$$

EVIDENCIA

EJEMPLO

5. En una asignatura universitaria de primero asisten a clase 100 de los 150 alumnos. Se sabe que aprueban el 90% de los alumnos que asisten a clase y el 30% de los que no asisten. Se elige un alumno al azar. Calcular:
- La probabilidad de que haya suspendido.
 - Si se sabe que el alumno ha suspendido, la probabilidad de que haya asistido a clase.

Causas: $A_1 \leftarrow$ Asiste a clase
 $A_2 \leftarrow$ No a clase

Suceso: $B \leftarrow$ Suspenden

$$(a) \quad P(B) = \underbrace{P(B|A_1)}_{1-0,9=0,1} \cdot \underbrace{P(A_1)}_{\frac{100}{150}} + \underbrace{P(B|A_2)}_{1-0,3=0,6} \cdot \underbrace{P(A_2)}_{\frac{50}{150}}$$
$$= \frac{10}{150} + \frac{30}{150} = \frac{40}{150} = \frac{4}{15}$$

$$(b) \quad P(A_1|B) = \frac{P(B|A_1) \cdot P(A_1)}{P(B)} = \frac{1/15}{4/15} = \frac{1}{4}$$

• Clasificación bayesiana

Target \rightarrow \boxed{y} = $\begin{pmatrix} y^{(1)} \\ \vdots \\ y^{(N)} \end{pmatrix}$ CATEGORÍAS
Variable categórica $\rightarrow C_1, \dots, C_N$

Training data: $X = \begin{pmatrix} x_1^{(1)} & \dots & x_m^{(1)} \\ \vdots & & \vdots \\ x_1^{(N)} & \dots & x_m^{(N)} \end{pmatrix} = \begin{pmatrix} \bar{x}^{(1)} \\ \vdots \\ \bar{x}^{(N)} \end{pmatrix}$ [Ej. Va a clase, No va a clase]

Dada una nueva instancia: $\vec{x} = (x_1, \dots, x_m) \rightarrow$ ¿y?

¿Prob. de que \vec{x} esté en la categoría C_k ?
 \downarrow
 $\boxed{P(C_k|\vec{x})}$
 \uparrow
¿ $P(y=C_k)$?

(TEST DATA) → A POSTERIORI

$$P(C_k | \bar{x}) = \frac{P(\bar{x} | C_k) \cdot P(C_k)}{P(\bar{x})}$$

← A PRIORI (TRAINING DATA)

← EVIDENCIA

VEROSIMILITUD (LIKELIHOOD)

$$P(C_k) = \frac{\# \text{ datos en } C_k}{\# \text{ datos total}} = \frac{\# \text{ datos en } C_k}{N}$$

Quiero hallar el K que maximiza $P(C_k | \bar{x})$

[Predecir C_k para la nueva instancia \bar{x}]

→ $P(\bar{x})$ no afecta al máximo →

$$\hat{y} = C_{\hat{K}}$$

↑
Quiero predecir la categoría

$$\hat{K} = \underset{K}{\text{indmax}} P(C_k | \bar{x})$$

El K tal que $P(C_k | \bar{x})$ es máximo

$$\hat{K} = \underset{K}{\text{indmax}} P(C_k | \bar{x}) = \underset{K}{\text{indmax}} P(\bar{x} | C_k) \cdot P(C_k)$$

↑
Esta es la terna

Esta es la terna

• Clasificador Bayesiano ingenues (Naive assumption)
 $\bar{x} = (x_1, \dots, x_n)$
 ↑ Suposición ingenua

Supongo que $P(x_1 | C_k), \dots, P(x_n | C_k)$ son variables independientes,

o decir:

$$P(\bar{x} | C_k) = P(x_1 | C_k) \cdot P(x_2 | C_k) \cdot \dots \cdot P(x_n | C_k)$$

[Asumo que las features son independientes]

Suponemos que conocemos las distribuciones de las $P(x_i | C_k)$ a priori:

Por ejemplo, las estimamos como distribuciones normales:

$$P(x_i | C_k) \sim \mathcal{N}(x_i | \mu_k^i, \sigma_k^i)$$

Medida de x_i en C_k

Varianza de x_i en C_k

$$\hat{K} = \underset{K}{\text{indmax}} \left[\mathcal{N}(x_1 | \mu_K^1, \sigma_K^1) \dots \mathcal{N}(x_n | \mu_K^n, \sigma_K^n) \frac{\#C_K}{N} \right]$$

El clasificador bayesiano ingenuo, asigna a una nueva columna (x_1, \dots, x_n) la categoría que maximice el número:

$$\mathcal{N}(x_1 | \mu_K^1, \sigma_K^1) \times \dots \times \mathcal{N}(x_n | \mu_K^n, \sigma_K^n) \frac{\#C_K}{N}$$

$$\mathcal{N}(x | \mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad \leftarrow \text{Recordad}$$