



Clasificación Supervisada

Métodos Estadísticos

Jesús Ariel Carrasco Ochoa

Instituto Nacional de Astrofísica, Óptica y Electrónica

Probabilidad

Probabilidad

$$P(X) = \frac{\text{\# de eventos a favor}}{\text{\# total de eventos posibles}}$$

Si ***X*** y ***Y*** son eventos excluyentes

$$P(X \vee Y) = P(X) + P(Y)$$

Probabilidad

Si **X** y **Y** son eventos independientes

$$P(X \wedge Y) = P(X)P(Y)$$

Si **X** y **Y** son eventos no independientes

$$P(X \wedge Y) = P(X)P(Y/X)$$

$$P(X \wedge Y) = P(Y)P(X/Y)$$

Probabilidad

Como tenemos 2 formas de calcular $P(X \wedge Y)$

$$P(Y)P(X/Y) = P(X)P(Y/X)$$

Despejando

$$P(X/Y) = \frac{P(X)P(Y/X)}{P(Y)}$$

Clasificación Bayesiana

- Sea T un conjunto de entrenamiento con n objetos O_1, \dots, O_n
- Los objetos de T están agrupados en 2 clases C_1 y C_2 y se conoce a la clase a la que pertenece cada objeto
- Sea n_1 el número de objetos de T en C_1 y n_2 el número de objetos de T en C_2
- Cada objeto O_j descrito por una sola variable x

Clasificación Bayesiana

Dado un nuevo objeto **O**

- En el enfoque estadístico se parte de la idea de colocar un objeto nuevo en la clase que sea más probable
- La forma más simple de hacerlo es colocarlo en la clase mas probable sin tomar en cuenta la descripción del objeto
 - Debemos conocer las probabilidades de cada clase (si no se conocen usualmente se aproximan como **$P(C_i) = n_i/n$**)
 - Todos los objetos nuevos se pondrán en la misma clase

Clasificación Bayesiana

Si el valor de \mathbf{O} en \mathbf{x} lo denotamos como $\mathbf{x}(\mathbf{O})$

- Para tomar en cuenta la descripción del objeto a clasificar debemos calcular las probabilidades condicionales

$P(\mathbf{O} \in C_i / \mathbf{x}(\mathbf{O}) = X)$ que denotaremos como $P(C_i / X)$

- Y colocar al objeto \mathbf{O} en la clase con mayor probabilidad

Clasificación Bayesiana

Cómo calcular $P(C_i/X)$?

$$P(C_i/X) = \frac{P(C_i)P(X/C_i)}{P(X)}$$

Donde $P(C_i)$ la aproximamos como

$$P(C_i) = \frac{n_i}{n}$$

Clasificación Bayesiana

Como queremos sólo saber cuál $P(C_i / X)$ es mayor podemos eliminar $P(X)$ y solamente calcular

$$P(C_i)P(X/C_i)$$

Si suponemos que $\mathbf{x} \sim N(\mu_i, \sigma_i^2)$ en C_i

$$P(X/C_i) = \frac{1}{\sqrt{2\pi}\sigma_i} e^{-\frac{1}{2} \frac{(X-\mu_i)^2}{\sigma_i^2}}$$

Clasificación Bayesiana

A \mathbf{O} se le asigna la clase C_0 si

$$C_0 = \max_{C_i} \{P(C_i)P(X/C_i)\}$$

Para $\mathbf{x} \sim N(\mu_i, \sigma_i^2)$ en C_i queda

$$C_0 = \max_{C_i} \left\{ \frac{n_i}{n} \frac{1}{\sqrt{2\pi\sigma_i}} e^{-\frac{1}{2} \frac{(X-\mu_i)^2}{\sigma_i^2}} \right\}$$

Clasificación Bayesiana

Tomado logaritmo natural queda

$$C_O = \max_{C_i} \left\{ \ln\left(\frac{n_i}{n}\right) - \ln\left(\sqrt{2\pi}\sigma_i\right) - \frac{(X - \mu_i)^2}{2\sigma_i^2} \right\}$$

Clasificación Bayesiana

De donde salen μ_i y σ_i^2 ?

Se aproximan con la media y la desviación estándar de la muestra

$$\mu_i = \bar{X}_i = \frac{1}{n_i} \sum_{O_j \in C_i} x(O_j)$$

$$\sigma_i^2 = S_i^2 = \frac{1}{n_i - 1} \sum_{O_j \in C_i} (x(O_j) - \bar{X}_i)^2$$

Clasificación Bayesiana

- Sea T un conjunto de entrenamiento con n objetos $\mathbf{O}_1, \dots, \mathbf{O}_n$
- Los objetos de T están agrupados en r clases $\mathbf{C}_1, \dots, \mathbf{C}_r$ y se conoce a la clase a la que pertenece cada objeto
- Sea n_i el número de objetos de T en \mathbf{C}_i
- Cada objeto \mathbf{O}_j descrito por m variables $\mathbf{x}_1, \dots, \mathbf{x}_m$

Clasificación Bayesiana

En este caso queremos calcular las probabilidades condicionales

$$P(O \in C_i / O = (x_1(O), \dots, x_m(O)))$$

Que denotaremos como

$$P(C_i / X)$$

Clasificación Bayesiana

Como queremos sólo saber cuál $P(C_i / X)$,
solamente calculamos

$$P(C_i)P(X / C_i)$$

Si suponemos que $\mathbf{x} \sim N(\mu_i, \Sigma_i)$ en C_i

$$P(X / C_i) = \frac{1}{\sqrt{(2\pi)^m |\Sigma_i|}} e^{-\frac{1}{2}(\mathbf{X} - \mu_i)^T \Sigma_i^{-1} (\mathbf{X} - \mu_i)}$$

Clasificación Bayesiana

A \mathbf{O} se le asigna la clase C_0 si

$$C_0 = \max_{C_i} \{P(C_i)P(X/C_i)\}$$

Para $\mathbf{x} \sim N(\mu_i, \Sigma_i)$ en C_i queda

$$C_0 = \max_{C_i} \left\{ \frac{n_i}{n} \frac{1}{\sqrt{(2\pi)^m |\Sigma_i|}} e^{-\frac{1}{2}(X-\mu_i)^T \Sigma_i^{-1} (X-\mu_i)} \right\}$$

Clasificación Bayesiana

Tomado logaritmo natural queda

$$C_O = \max_{C_i} \left\{ \ln\left(\frac{n_i}{n}\right) - \ln\left(\sqrt{2\pi|\Sigma_i|}\right) - \frac{1}{2}(X - \mu_i)^T \Sigma_i^{-1}(X - \mu_i) \right\}$$

Clasificación Bayesiana

De dónde salen μ_i y Σ_i ?

Se aproximan con la media y la desviación estándar de la muestra

$$\mu_i = \bar{X}_i = \frac{1}{n_i} \sum_{O_j \in C_i} (x_1(O_j), \dots, x_m(O_j))$$

$$\Sigma_i = S_{ij} = \frac{1}{n_i - 1} \sum_{O_j \in C_i} (X_j - \bar{X}_i)(X_j - \bar{X}_i)^T$$

Clasificador Simple de Bayes (Naïve Bayes)

Para simplificar el trabajo se asume que las variables que describen a los objetos son independientes con lo que

$$P(X/C_i) = \prod_{j=1}^m P(X_j/C_i)$$

Clasificador Simple de Bayes (Naïve Bayes)

Si suponemos que $\mathbf{X}_j \sim N(\mu_{ij}, \sigma_{ij}^2)$ en C_i

$$P(X/C_i) = \prod_{j=1}^m \left(\frac{1}{\sqrt{2\pi\sigma_{ij}}} e^{-\frac{1}{2} \frac{(X_j - \mu_{ij})^2}{\sigma_{ij}^2}} \right)$$

Clasificador Simple de Bayes (Naïve Bayes)

A \mathbf{O} se le asigna la clase C_0 si

$$C_0 = \max_{C_i} \{P(C_i)P(X/C_i)\}$$

Para $\mathbf{X}_j \sim N(\mu_{ij}, \sigma_{ij}^2)$ en C_i queda

$$C_0 = \max_{C_i} \left\{ \frac{n_i}{n} \prod_{j=1}^m \left(\frac{1}{\sqrt{2\pi\sigma_{ij}}} e^{-\frac{1}{2} \frac{(X_j - \mu_{ij})^2}{\sigma_{ij}^2}} \right) \right\}$$

Clasificador Simple de Bayes (Naïve Bayes)

Tomado logaritmo natural queda

$$C_O = \max_{C_i} \left\{ \ln\left(\frac{n_i}{n}\right) + \sum_{j=1}^m \left(-\ln\left(\sqrt{2\pi}\sigma_{ij}\right) - \frac{(X - \mu_{ij})^2}{2\sigma_{ij}^2} \right) \right\}$$

$$C_O = \max_{C_i} \left\{ \ln\left(\frac{n_i}{n}\right) - \sum_{j=1}^m \ln\left(\sqrt{2\pi}\sigma_{ij}\right) - \sum_{j=1}^m \frac{(X - \mu_{ij})^2}{2\sigma_{ij}^2} \right\}$$

Estimación de la función de densidad

Se buscan los k vecinos más cercanos a X en C_i

Sea $d_k(X)$ la distancia entre X y el vecino más lejano de los k más cercanos

Sea k_i el número de objetos en C_i entre los más cercanos a X

Estimación de la función de densidad

La función de densidad de \mathbf{X} en \mathbf{C}_i puede estimarse como:

$$\hat{P}(X/C_i) = \frac{k_i}{n_i V_k(X)}$$

donde

$$V_k(X) = \frac{\pi^{\frac{n}{2}} (d_k(X))^n}{\Gamma\left(\frac{n}{2} + 1\right)}$$

$$\Gamma\left(\frac{n}{2} + 1\right) = \begin{cases} \left(\frac{n}{2}\right)! & \text{si } n \text{ es par} \\ \left(\frac{n}{2}\right) \Gamma\left(\frac{n}{2}\right) & \text{si } n \text{ es impar, con } \Gamma(0.5) = \sqrt{\pi} \end{cases}$$

Estimación de la función de densidad

Podemos analizar qué tan buena es la suposición de que los datos siguen una cierta distribución

Si suponemos que \mathbf{X} sigue la distribución $f(\mathbf{X})$ en \mathbf{C}_i entonces

$$P(\mathbf{X}/\mathbf{C}_i) = f(\mathbf{X})$$

Estimación de la función de densidad

Calcular

$$\chi_i^2 = n_i \sum_{j=1}^{n_i} \frac{\left(\hat{P}(X_j / C_i) - P(X_j / C_i)\right)^2}{P(X_j / C_i)}$$

- Con **$n_i - s - 1$** grados de libertad
- **s** es el número de parámetros estimados
- Se debe cumplir que **$n_i \geq s + 1$**

Estimación de la función de densidad

Si suponemos $\mathbf{X} \sim \mathbf{N}(\mu_i, \Sigma_i)$ en \mathbf{C}_i

n medias
 $\frac{n(n+1)}{2}$ varianzas

$$s = n + \frac{n(n+1)}{2} = \frac{n(n+3)}{2}$$

Estimación de la función de densidad

Se define el porcentaje de riesgo

Se checa en la tabla de χ^2 si el valor calculado es mayor que el máximo esperado

SI \rightarrow Se rechaza la hipótesis

NO \rightarrow No se rechaza ("se acepta") la hipótesis



Clasificación Supervisada

Métodos Estadísticos

Jesús Ariel Carrasco Ochoa

Instituto Nacional de Astrofísica, Óptica y Electrónica