

Signaux Aléatoires

Classification Bayésienne

Jean-Yves Tournet⁽¹⁾

(1) University of Toulouse, ENSEEIHT-IRIT-TéSA
jyt@n7.fr

Année 2023 – 2024

Bibliographie


Quelques références

- ▶ R. O. Duda, P. E. Hart and D. G. Stork, *Pattern Classification*, 2nd edition, Wiley, 2000.
- ▶ S. Theodoridis and K. Koutroumbas, *Pattern Recognition*, 4th edition, Academic Press, 2008.
- ▶ A. Jain, R. Duin and J. Mao, *Statistical Pattern Recognition: A Review*, IEEE Transactions Pattern Analysis and Machine Intelligence, vol. 22, no. 1, pp. 4-37, Jan. 2000.

Applications



ChatGPT		
Examples	Capabilities	Limitations
"Explain quantum computing in simple terms" →	Remembers what user said earlier in the conversation	May occasionally generate incorrect information
"Get any creative ideas for a 10 year old's birthday" →	Allows user to provide follow-up corrections	May occasionally produce harmful instructions or biased content
"How do I make an HTTP request in Javascript" →	Trained to decline inappropriate requests	Limited knowledge of world and events after 2021



Classification

Notations

- ▶ K classes $\omega_1, \dots, \omega_K$
- ▶ $\mathbf{x} = [x(1), \dots, x(p)]^T$ **vecteur d'observations** $\in X = \mathbb{R}^p$
- ▶ A : ensemble d'**actions** a_1, \dots, a_q où a_k "affecte le vecteur \mathbf{x} dans la classe ω_k " avec $k = 1, \dots, K$

Definition

$$d: \begin{array}{l} X \rightarrow A \\ \mathbf{x} \mapsto d(\mathbf{x}) \end{array}$$

Remarque

Classification **avec reject**: $A = \{a_0, a_1, \dots, a_K\}$ où $a_0 =$ "on ne classe pas le vecteur \mathbf{x} "

Classification Bayésienne

Hypothèses : modèle probabiliste

- ▶ Probabilité *a priori* de la classe ω_k

$$P(\omega_k)$$

- ▶ Densité de probabilité du vecteur \mathbf{x} conditionnelle à la classe ω_k

$$p(\mathbf{x} | \omega_k)$$


Conclusion

- ▶ Probabilité *a posteriori* que \mathbf{x} appartienne à la classe ω_k

$$P(\omega_k | \mathbf{x}) = \frac{p(\mathbf{x} | \omega_k) P(\omega_k)}{p(\mathbf{x})}$$

avec $p(\mathbf{x}) = \sum_{k=1}^K p(\mathbf{x} | \omega_k) P(\omega_k)$.

Exemple



Classifieur du maximum a posteriori (MAP)

Définition

$$d^*(\mathbf{x}) = a_j \Leftrightarrow P(\omega_j | \mathbf{x}) \geq P(\omega_k | \mathbf{x}), \forall k \in \{1, \dots, K\}$$

Classes équiprobable : classifieur du maximum de vraisemblance

$$d^*(\mathbf{x}) = a_j \Leftrightarrow p(\mathbf{x} | \omega_j) \geq p(\mathbf{x} | \omega_k), \forall k \in \{1, \dots, K\}$$

Propriété

Le classifieur MAP minimise la probabilité d'erreur de classification

Preuve (2 classes)

Probabilité d'erreur

$$\begin{aligned} P_e &= P[d(\mathbf{x}) = a_1 \cap \mathbf{x} \in \omega_2] + P[d(\mathbf{x}) = a_2 \cap \mathbf{x} \in \omega_1] \\ &= P[d(\mathbf{x}) = a_1 \mid \mathbf{x} \in \omega_2] P(\omega_2) + P[d(\mathbf{x}) = a_2 \mid \mathbf{x} \in \omega_1] P(\omega_1) \end{aligned}$$

Soit $R_i = \{\mathbf{x} \in \mathbb{R}^p / d(\mathbf{x}) = a_i\}$ la région associée à l'acceptation de la classe ω_i

$$\begin{aligned} P_e &= \int_{R_1} P(\omega_2) p(\mathbf{x} \mid \omega_2) d\mathbf{x} + \int_{R_2} P(\omega_1) p(\mathbf{x} \mid \omega_1) d\mathbf{x} \\ &= P(\omega_2) \left[1 - \int_{R_2} p(\mathbf{x} \mid \omega_2) d\mathbf{x} \right] + \int_{R_2} P(\omega_1) p(\mathbf{x} \mid \omega_1) d\mathbf{x} \\ &= P(\omega_2) + \int_{R_2} [P(\omega_1) p(\mathbf{x} \mid \omega_1) - P(\omega_2) p(\mathbf{x} \mid \omega_2)] d\mathbf{x} \\ &= P(\omega_2) - \int_{R_2} [P(\omega_2 \mid \mathbf{x}) - P(\omega_1 \mid \mathbf{x})] p(\mathbf{x}) d\mathbf{x} \end{aligned}$$

P_e est minimum lorsque $R_2 = \{\mathbf{x} / P(\omega_2 \mid \mathbf{x}) > P(\omega_1 \mid \mathbf{x})\}$

Probabilité d'erreur (K classes)

Définition

$$P_e = \sum_{k=1}^K P[d(\mathbf{x}) = a_k \cap \mathbf{x} \notin \omega_k]$$

Propriété

Le classifieur MAP minimise P_e

Preuve

admise

Cas gaussien

Densité

$$p(\mathbf{x} | \omega_k) = \frac{1}{(2\pi)^{p/2} \sqrt{\det \Sigma_k}} \exp \left[-\frac{1}{2} (\mathbf{x} - \mathbf{m}_k)^T \Sigma_k^{-1} (\mathbf{x} - \mathbf{m}_k) \right]$$

Cas général

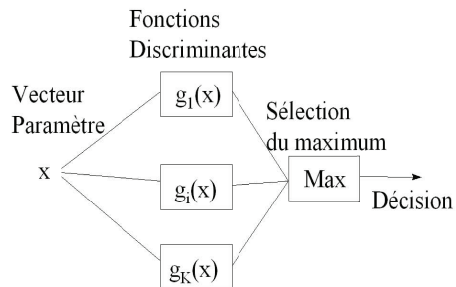
$$d^*(\mathbf{x}) = a_i \Leftrightarrow g_i(\mathbf{x}) \geq g_k(\mathbf{x}) \quad \forall k = 1, \dots, K$$

avec

$$g_i(\mathbf{x}) = -(\mathbf{x} - \mathbf{m}_i)^T \Sigma_i^{-1} (\mathbf{x} - \mathbf{m}_i) - \ln \det \Sigma_i + 2 \ln P(\omega_i)$$

Cas Gaussien

Classifieur



Fonctions discriminantes : Terme quadratique + terme linéaire + constante

Matrices de covariance identiques ($\Sigma_i = \Sigma$)

Classes équiprobables : règles de la distance aux barycentres

$$d^*(\mathbf{x}) = a_i \Leftrightarrow d_M(\mathbf{x}, \mathbf{m}_i) \leq d_M(\mathbf{x}, \mathbf{m}_k) \quad \forall k = 1, \dots, K$$

où d_M est la **distance de Mahalanobis**

$$d_M(\mathbf{x}, \mathbf{m}_k) = \sqrt{(\mathbf{x} - \mathbf{m}_k)^T \Sigma^{-1} (\mathbf{x} - \mathbf{m}_k)}$$

Classes non équiprobables : fonctions discriminantes affines

$$d^*(\mathbf{x}) = a_i \Leftrightarrow \left[\mathbf{x} - \frac{1}{2} (\mathbf{m}_i + \mathbf{m}_k) \right]^T \Sigma^{-1} (\mathbf{m}_i - \mathbf{m}_k) \geq \ln \frac{P(\omega_k)}{P(\omega_i)}, \quad \forall k$$

Que faut-il savoir ?

- ▶ Règle de classification Bayésienne
- ▶ Équivalence avec le classifieur du maximum de vraisemblance et de la règle de la distance aux barycentres
- ▶ Calcul de la probabilité d'erreur du classifieur Bayésien