

Théorie bayésienne de la décision



A. Rakotomamonjy, R. Flamary

8 avril 2013

◀ ▶ ⏪ ⏩ 🔍 ↺

Introduction par l'exemple


- ▶ On a l'information de luminance \mathbf{x} une v.a de densité de probabilité $p(\mathbf{x})$
- ▶ on suppose que l'on connaît les densités de probabilité conditionnelle de x sachant les classes ω_j : $p(\mathbf{x}|\omega_1)$ et $p(\mathbf{x}|\omega_2)$.
- ▶ Règle de Bayes : $p(\mathbf{x}, \omega_i) = p(\mathbf{x}|\omega_i)p(\omega_i) = p(\omega_i|\mathbf{x})p(\mathbf{x})$
- ▶ on affecte \mathbf{x} à la classe de plus forte probabilité a posteriori



◀ ▶ ⏪ ⏩ 🔍 ↺

Introduction par l'exemple

- ▶ On tire un pixel de l'image au hasard et on cherche à prédire si il provient de la zone 1 (sombre) ou de la zone 2(clair) avec le moins d'erreur possible
- ▶ comment décider si on a aucune information ?
- ▶ comment décider si on a une information de luminance du pixel ?



◀ ▶ ⏪ ⏩ 🔍 ↺

Test du Rapport de vraisemblance

Cadre

- ▶ On veut catégoriser un objet à partir d'un ensemble de caractéristiques \mathbf{x} et à l'aide de la vraisemblance de ce vecteur vis à vis des classes ω_j .
- ▶ une règle de décision intuitif et raisonnable est : "choisir la classe la plus probable étant donné l'observation \mathbf{x} ."
 - ▶ Formellement : on évalue les probabilités $P(\omega_j|\mathbf{x})$ pour tout j et on choisit la classe qui maximise $P(\omega_j|\mathbf{x})$.

Analyse dans le cas où on a 2 classes

- ▶ Cette règle de décision s'écrit :

$$\text{si } P(\omega_1|\mathbf{x}) > P(\omega_2|\mathbf{x}) \text{ choisir } \omega_1 \text{ sinon } \omega_2 \text{ ou } P(\omega_1|\mathbf{x}) \gtrless_{\omega_2} P(\omega_2|\mathbf{x})$$

◀ ▶ ⏪ ⏩ 🔍 ↺

Test du Rapport de Vraisemblance

En appliquant le théorème de Bayes, on a

$$\frac{p(\mathbf{x}|\omega_1)p(\omega_1)}{p(\mathbf{x})} \underset{\omega_2}{\overset{\omega_1}{\geq}} \frac{p(\mathbf{x}|\omega_2)p(\omega_2)}{p(\mathbf{x})}$$

Comme $p(\mathbf{x})$ est toujours positif et n'influe pas dans le test, il peut être éliminé, on a alors

$$\Lambda(\mathbf{x}) = \frac{p(\mathbf{x}|\omega_1)}{p(\mathbf{x}|\omega_2)} \underset{\omega_2}{\overset{\omega_1}{\geq}} \frac{p(\omega_2)}{p(\omega_1)}$$

$\Lambda(\mathbf{x})$ est appelé le **rapport de vraisemblance** et la règle de décision le **test de rapport de vraisemblance**




Exemple de Test de RV

- On a un problème de catégorisation à deux classes et on connaît les lois conditionnelles des caractéristiques sachant les classes

$$p(\mathbf{x}|\omega_i) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-\mu_i)^2}$$

avec $\mu_1 = 4$ et $\mu_2 = 10$. On suppose que les lois a priori de chaque classe sont égales i.e $p(\omega_1) = p(\omega_2)$

- quel est la règle de décision définie par le test de RV ?
 - On décide ω_1 dans la région $R_1 : x \geq 7$ et ω_2 dans la région $R_2 : x < 7$
 - résultat intuitif étant donné les lois



- que devient cette règle si $p(\omega_1) = 2p(\omega_2)$




Probabilité d'erreur

- La performance d'une règle de décision donnée peut être évalué par sa **probabilité d'erreur** $P(Err)$, qui peut s'écrire étant donné, le théorème des probabilités totales $P(Err) = \sum_{i=1}^C P(Err|\omega_i)P(\omega_i)$
- La probabilité conditionnelle d'erreur sachant la classe peut également s'exprimer comme

$$P(Err|\omega_i) = P(\text{choisir } \omega_j|\omega_i) = \int_{R_j} p(\mathbf{x}|\omega_i) d\mathbf{x}$$

- Dans le cas à deux classes, on a donc

$$P(Err) = P(\omega_1) \int_{R_2} p(\mathbf{x}|\omega_1) d\mathbf{x} + P(\omega_2) \int_{R_1} p(\mathbf{x}|\omega_2) d\mathbf{x}$$




Probabilité d'erreur et Test RV

- Est-ce que ce que le test de Rapport de Vraisemblance est une bonne règle de décision ?
 - Pour répondre à cette question, on s'intéresse à la probabilité conditionnelle d'erreur $P(Err|\mathbf{x})$

$$P(Err) = \int_{\mathbf{x}} P(Err|\mathbf{x})p(\mathbf{x})d\mathbf{x}$$

- la règle optimale minimise $P(Err|\mathbf{x})$ pour tout \mathbf{x}
- en un point \mathbf{x}' , $P(Err|\mathbf{x}')$ est égale à $P(\omega_j|\mathbf{x}')$ quand la classe ω_j est choisie.



- De la figure, on devine que pour tout \mathbf{x}' , la règle de décision issue du Test de RV admet un $P(Err|\mathbf{x}')$ plus faible que celle d'une règle alternative
- Pour tout problème de catégorisation, la règle de décision issue du Test de RV admet la plus faible probabilité d'erreur. Cette probabilité d'erreur est appelé **Erreur de Bayes**.



Risque de Bayes

- ▶ Pour le calcul de l'erreur de Bayes, on fait l'hypothèse qu'une erreur de catégorisation admet le même coût.
 - ▶ Cette hypothèse n'est pas vérifiée dans beaucoup de situations. Par exemple, le cas des diagnostic médical
- ▶ On formalise ce concept en introduisant la notion de coût $C_{i,j}$
 - ▶ $C_{i,j}$ représente le coût de choisir ω_i alors que la vraie classe est ω_j .
- ▶ On définit le **risque de Bayes** comme étant l'espérance du coût $\mathcal{R} = E(C)$

$$E(C) = \sum_i \sum_j C_{i,j} P(\text{choisir } \omega_i \text{ et } \mathbf{x} \in \omega_j) = \sum_i \sum_j C_{i,j} P(\mathbf{x} \in R_i | \omega_j) P(\omega_j)$$

- ▶ Quelle est la règle de décision qui minimise le risque de Bayes dans le cas 2 classes ?
 - ▶ On note tout d'abord que

$$P(\mathbf{x} \in R_i | \omega_j) = \int_{R_i} p(\mathbf{x} | \omega_j) d\mathbf{x}$$

Navigation icons

Risque de Bayes (2)

- ▶ Le risque s'écrit

$$\mathcal{R} = \int_{R_1} [C_{11}P(\omega_1)p(\mathbf{x}|\omega_1) + C_{12}P(\omega_2)p(\mathbf{x}|\omega_2)]d\mathbf{x} + \int_{R_2} [C_{21}P(\omega_1)p(\mathbf{x}|\omega_1) + C_{22}P(\omega_2)p(\mathbf{x}|\omega_2)]d\mathbf{x}$$

- ▶ et comme $\int_{R_2} p(\mathbf{x}|\omega_i)d\mathbf{x} = 1 - \int_{R_1} p(\mathbf{x}|\omega_i)d\mathbf{x}$, on a

$$\mathcal{R} = C_{21}P(\omega_1) + C_{22}P(\omega_2) + (C_{12} - C_{22})P(\omega_2) \int_{R_1} P(\mathbf{x}|\omega_2)d\mathbf{x} - (C_{21} - C_{11})P(\omega_1) \int_{R_1} P(\mathbf{x}|\omega_1)d\mathbf{x}$$

- ▶ Si on cherche à minimiser le risque, les deux premiers termes sont sans influence et on cherche donc une règle de décision telle que la région R_1 définie par cette règle minimise


$$R_1 = \arg \min \int_{R_1} [(C_{12} - C_{22})P(\omega_2)P(\mathbf{x}|\omega_2) - (C_{21} - C_{11})P(\omega_1)P(\mathbf{x}|\omega_1)] d\mathbf{x} = \arg \min \int_{R_1} g(\mathbf{x}) d\mathbf{x}$$

Navigation icons

Risque de Bayes (3)

Intuition sur $g(x)$ et la région R_1

- ▶ On cherche une région R_1 qui minimise l'intégrale $\int_{R_1} g(x)dx$. On cherche donc les régions telles que $g(x) < 0$



- ▶ On choisit donc R_1 tel que

$$(C_{21} - C_{11})P(\omega_1)P(\mathbf{x}|\omega_1) > (C_{12} - C_{22})P(\omega_2)P(\mathbf{x}|\omega_2)$$

- ▶ En ré-arrangeant les termes, la règle de décision minimisant le risque de Bayes est

$$\Lambda(x) = \frac{p(\mathbf{x}|\omega_1)}{p(\mathbf{x}|\omega_2)} \underset{\omega_2}{\overset{\omega_1}{\geq}} \frac{C_{12} - C_{22}}{C_{21} - C_{11}} \frac{p(\omega_2)}{p(\omega_1)}$$

qui est également défini par un test de rapport de vraisemblance

Navigation icons

Exemple de Risque de Bayes

- ▶ Problème de catégorisation à deux classes

$$\text{avec } p(\mathbf{x}|\omega_1) = \frac{1}{\sqrt{2\pi}\sqrt{3}} e^{-\frac{1}{2} \frac{x^2}{3}},$$

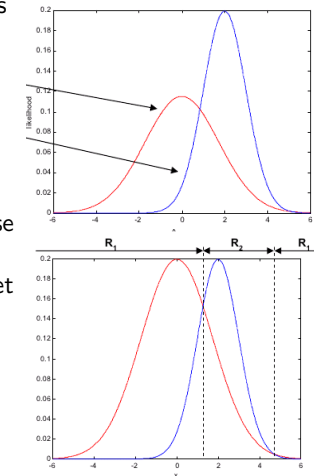
$$p(\mathbf{x}|\omega_2) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-2)^2}$$

- ▶ tracer les densités
- ▶ que vaut le rapport de vraisemblance ?
- ▶ quelle est la règle de décision qui minimise le risque de Bayes ? si

$$P(\omega_1) = P(\omega_2), C_{11} = C_{22} = 0, C_{12} = 1 \text{ et } C_{21} = \sqrt{3}$$

- ▶

$$2x^2 - 12x + 12 \underset{\omega_2}{\overset{\omega_1}{\geq}} 0$$



Navigation icons

Variations sur un même thème : Test du RV

- Le classifieur basé sur le test du RV qui minimise le risque de Bayes s'écrit

$$\Lambda(x) = \frac{p(x|\omega_1)}{p(x|\omega_2)} \underset{\omega_2}{\overset{\omega_1}{\geq}} \frac{C_{12}-C_{22}}{C_{21}-C_{11}} \frac{p(\omega_2)}{p(\omega_1)}$$

et est appelé **Classifieur de Bayes**

- Le classifieur basé sur le test du RV qui minimise la probabilité d'erreur ($C_{ij} = 1$ si $i = j$ et 0 sinon) s'écrit

$$\Lambda(x) = \frac{p(x|\omega_1)}{p(x|\omega_2)} \underset{\omega_2}{\overset{\omega_1}{\geq}} \frac{p(\omega_2)}{p(\omega_1)} \Leftrightarrow \Lambda(x) = \frac{p(\omega_1|x)}{p(\omega_2|x)} \underset{\omega_2}{\overset{\omega_1}{\geq}} 1$$

et est appelé **Classifieur du maximum à posteriori**


- Le classifieur basé sur le test du RV qui minimise la probabilité d'erreur sachant que les classes ont une probabilité égale $P(\omega_1) = P(\omega_2) = 0.5$

$$\Lambda(x) = \frac{p(x|\omega_1)}{p(x|\omega_2)} \underset{\omega_2}{\overset{\omega_1}{\geq}} 1$$

et est appelé **Classifieur du maximum de vraisemblance**

Probabilité d'erreur dans le cas de plusieurs classes

- Pour maximiser $P(Corr)$, il s'agit donc de maximiser chaque intégrale. Cela s'obtient en choisissant, pour un x donnée, la classe qui maximise $P(\omega_i|x)$.
- La région R_i est définie comme la région où $P(\omega_i|x)$ est maximum.
- La règle de décision qui minimise la probabilité d'erreur est la règle qui maximise le **critère de maximum a posteriori**.



Probabilité d'erreur dans le cas de plusieurs classes

- La règle de décision qui minimise la probabilité d'erreur se généralise facilement au cas multi-classe.
- La probabilité d'erreur s'obtient, dans ce cas, par la probabilité de bonne catégorisation

$$P(Err) = 1 - P(Corr) = 1 - \sum_{i=1}^C P(\omega_i) \int_{R_i} p(x|\omega_i) dx$$

- On cherche de manière équivalente à maximiser la probabilité de bonne catégorisation

$$P(Corr) = \sum_{i=1}^C P(\omega_i) \int_{R_i} p(x|\omega_i) dx = \sum_{i=1}^C \int_{R_i} p(x|\omega_i) P(\omega_i) dx = \sum_{i=1}^C \int_{R_i} p(\omega_i|x)$$

- Pour maximiser $P(Corr)$, il s'agit donc de maximiser chaque intégrale. Cela s'obtient en choisissant, pour un x donnée, la classe qui maximise $P(\omega_i|x)$.

Risque de Bayes dans le cas multi-classe

- Pour déterminer la règle de décision qui minimise le risque de Bayes dans le cas multi-classe, on appelle
 - α_i , la décision de choisir la classe ω_i
 - $\alpha(x)$ la règle de décision qui associe à un vecteur de caractéristique x une classe ω_i
- le risque conditionnel associé à α_i , étant donné l'observation x est :

$$R(\alpha_i|x) = \sum_{j=1}^C C_{i,j} P(\omega_j|x)$$

- et le risque associé à une règle de décision $\alpha(x)$ est

$$R(\alpha(x)) = \int R(\alpha(x)|x) p(x) dx$$

- si on veut minimiser ce risque, on minimise le risque conditionnel pour tout x . Cela consiste à choisir la classe ω_i pour lequel $R(\alpha_i|x)$ est minimum, i.e la classe i telle que $\sum_{j=1}^C C_{i,j} P(\omega_j|x) < \sum_{k=1}^C C_{k,j} P(\omega_j|x) \forall k$

Fonctions discriminantes

- ▶ L'ensemble des règles de décision que nous avons vu ont la même structure
 - ▶ un vecteur de caractéristiques \mathbf{x} est assignée à la classe qui maximise (ou minimise) une certaine mesure $g_i(\mathbf{x})$
- ▶ Cette structure peut se formaliser à l'aide d'un ensemble de fonctions discriminantes $\{g_i(\mathbf{x})\}_{i=1}^C$ et la règle de décision définit comme

assigner \mathbf{x} à la classe ω_i telle que $g_i(\mathbf{x}) > g_j(\mathbf{x}), \forall j \neq i$

- ▶ Pour les trois règles de décision qui nous intéressent, nous avons :

| Classifieur | Fonctions discriminantes |
|--------------------------|---|
| Bayes | $g_i(\mathbf{x}) = -R(\alpha_i \mathbf{x})$ |
| Maximum a Posteriori | $g_i(\mathbf{x}) = P(\omega_i \mathbf{x})$ |
| Maximum de Vraisemblance | $g_i(\mathbf{x}) = p(\mathbf{x} \omega_i)$ |



Cas 1 : $\Sigma_i = \sigma^2 I$

- ▶ les caractéristiques sont statistiquement indépendants et de même variance pour toutes les classes
- ▶ la fonction discriminante quadratique $g_i(\mathbf{x})$ devient

$$g_i(\mathbf{x}) = -\frac{1}{2\sigma^2}(\mathbf{x} - \mu_i)^T(\mathbf{x} - \mu_i) - \frac{1}{2}d \log(\sigma^2) + \log(P(\omega_i))$$

d étant la dimensionalité du problème.

- ▶ En laissant de coté les termes constants et en développant, on a

$$g_i(\mathbf{x}) = -\frac{1}{2\sigma^2}(\mathbf{x}^T \mathbf{x} - 2\mu_i^T \mathbf{x} + \mu_i^T \mu_i) + \log(P(\omega_i))$$

- ▶ En éliminant les termes $\mathbf{x}^T \mathbf{x}$ qui sont constant pour toutes les fonctions discriminantes, on a

$$g_i(\mathbf{x}) = \mathbf{w}_i^T \mathbf{x} + w_0 \quad \text{avec } \mathbf{w}_i = \frac{\mu_i}{\sigma^2} \text{ et } w_0 = -\frac{1}{2\sigma^2} \mu_i^T \mu_i + \log P(\omega_i)$$

- ▶ La fonction de décision est **linéaire**
- ▶ si en plus, on fait l'hypothèse que les $P(\omega_i)$ sont égaux, alors

$$g_i(\mathbf{x}) = -\frac{1}{2\sigma^2}(\mathbf{x} - \mu_i)^T(\mathbf{x} - \mu_i)$$

on obtient un classifieur basé sur la distance minimum à la moyenne



Classifieur à minimum d'erreur pour des classes de lois Gaussiennes

- ▶ Dans ce cas, on s'intéresse aux fonctions discriminantes de la forme $g_i(\mathbf{x}) = P(\omega_i|\mathbf{x})$
- ▶ On montre dans ce qui suit que pour des données suivant une loi Gaussienne ces fonctions discriminantes peuvent prendre une expression très simple
- ▶ Expression générale
 - ▶ $p(\mathbf{x}|\omega_i)$ est une loi normale

$$p(\mathbf{x}|\omega_i) = \frac{1}{2\pi^{d/2} |\Sigma_i|^{1/2}} e^{-\frac{1}{2}(\mathbf{x} - \mu_i)\Sigma_i^{-1}(\mathbf{x} - \mu_i)}$$

- ▶ le théorème de Bayes donne

$$g_i(\mathbf{x}) = P(\omega_i|\mathbf{x}) = \frac{p(\mathbf{x}|\omega_i)p(\omega_i)}{p(\mathbf{x})} = \frac{1}{2\pi^{d/2} |\Sigma_i|^{1/2}} e^{-\frac{1}{2}(\mathbf{x} - \mu_i)\Sigma_i^{-1}(\mathbf{x} - \mu_i)} P(\omega_i) \frac{1}{p(\mathbf{x})}$$

- ▶ En éliminant les termes constants en i et en prenant le log (fonction croissante qui ne modifie pas la relation d'ordre), on a

$$g_i(\mathbf{x}) = -\frac{1}{2}(\mathbf{x} - \mu_i)\Sigma_i^{-1}(\mathbf{x} - \mu_i) - \frac{1}{2} \log(|\Sigma_i|) + \log(P(\omega_i))$$





Cas 1 : $\Sigma_i = \sigma^2 I$ - Exemple

- ▶ illustration pour un cas à trois classes et 2 dimensions :

$$\mu_1 = (3 \ 2)^T \quad \mu_2 = (7 \ 4)^T \quad \mu_3 = (2 \ 7)^T$$

$$\text{et } \Sigma = \begin{pmatrix} 2 & 0 \\ 0 & 2 \end{pmatrix}$$



Cas 2 : $\Sigma_i = \Sigma$ avec Σ diagonal

- ▶ Les classes ont la même matrice de covariance mais les caractéristiques ont des variances différentes
- ▶ la fonction discriminante quadratique $g_i(\mathbf{x})$ devient

$$g_i(\mathbf{x}) = -\frac{1}{2} \sum_{k=1}^d \frac{(\mathbf{x}_k - \mu_{i,k})^2}{\sigma_k^2} - \frac{1}{2} \log(\prod_{k=1}^d \sigma_k^2) + \log(P(\omega_i))$$

- ▶ en développant et en éliminant les termes $\mathbf{x}^T \mathbf{x}$ qui sont constants pour toutes les fonctions discriminantes, on a

$$g_i(\mathbf{x}) = \mathbf{w}_i^T \mathbf{x} + w_{i,0} \quad \text{avec } \mathbf{w}_{i,k} = -\frac{\mu_{i,k}}{\sigma_k^2} \text{ et } w_{i,0} = -\sum_k \frac{\mu_{i,k}^2}{2\sigma_k^2} + \log P(\omega_i)$$

- ▶ On obtient encore une fonction de décision linéaire





Cas 2 : $\Sigma_i = \Sigma$ avec Σ diagonal

- ▶ illustration pour un cas à trois classes et 2 dimensions :

$$\mu_1 = (3 \ 2)^T \quad \mu_2 = (5 \ 4)^T \quad \mu_3 = (2 \ 5)^T$$

$$\text{et } \Sigma = \begin{pmatrix} 1 & 0 \\ 0 & 2 \end{pmatrix}$$



Cas 3 : $\Sigma_i = \Sigma$ avec Σ quelconque

- ▶ Les classes ont la même matrice de covariance
- ▶ la fonction discriminante quadratique $g_i(\mathbf{x})$ devient

$$g_i(\mathbf{x}) = -\frac{1}{2} (\mathbf{x} - \mu_i)^T \Sigma_i^{-1} (\mathbf{x} - \mu_i) - \frac{1}{2} \log(|\Sigma_i|) + \log(P(\omega_i))$$


- ▶ En remplaçant Σ_i par Σ et en éliminant les termes constants pour toutes les classes, on a :

$$g_i(\mathbf{x}) = -\frac{1}{2} (\mathbf{x} - \mu_i)^T \Sigma^{-1} (\mathbf{x} - \mu_i) + \log(P(\omega_i))$$

- ▶ le terme quadratique est un terme important en reconnaissance de formes, il se nomme **distance de Mahalanobis**

$$\|\mathbf{x} - \mathbf{y}\|_{\Sigma^{-1}}^2 = (\mathbf{x} - \mathbf{y})^T \Sigma^{-1} (\mathbf{x} - \mathbf{y})$$

- ▶ La distance de Mahalanobis utilise une métrique en Σ^{-1} qui a tendance à étirer et "tordre" l'espace



Cas 3 : $\Sigma_i = \Sigma$ avec Σ quelconque

- ▶ En développant le terme quadratique et en supprimant les termes constants pour toutes les classes, on obtient

$$g_i(\mathbf{x}) = -\frac{1}{2} (-2\mu_i^T \Sigma^{-1} \mathbf{x} + \mu_i^T \Sigma^{-1} \mu_i) + \log(P(\omega_i))$$

- ▶ en réorganisant, on a

$$g_i(\mathbf{x}) = \mathbf{w}_i^T \mathbf{x} + w_{i,0} \quad \text{avec } \mathbf{w}_i = \Sigma^{-1} \mu_i \text{ et } w_{i,0} = -\frac{1}{2} \mu_i^T \Sigma^{-1} \mu_i + \log(P(\omega_i))$$

- ▶ Les fonctions discriminantes sont toujours linéaire
- ▶ Si on suppose que les classes sont équiprobables, on a

$$g_i(\mathbf{x}) = -\frac{1}{2} (\mathbf{x} - \mu_i)^T \Sigma^{-1} (\mathbf{x} - \mu_i)$$

- et le classifieur devient un classifieur basé sur la distance de Mahalanobis minimum à la moyenne





Cas 3 : $\Sigma_i = \Sigma$ avec Σ quelconque - Exemple

- ▶ illustration pour un cas à trois classes et 2 dimensions :

$$\mu_1 = (3 \ 2)^T \quad \mu_2 = (5 \ 4)^T \quad \mu_3 = (2 \ 5)^T$$

$$\text{et } \Sigma = \begin{pmatrix} 1 & 0.7 \\ 0.7 & 2 \end{pmatrix}$$



Navigation icons: back, forward, search, etc.

Cas 4 : $\Sigma_i = \sigma_i^2 I$

- ▶ Chaque classe a une matrice de covariance différente mais proportionnelle à la matrice identité
- ▶ La fonction discriminante devient

$$g_i(\mathbf{x}) = -\frac{1}{2\sigma_i^2}(\mathbf{x} - \mu_i)^T(\mathbf{x} - \mu_i) - \frac{1}{2}N \log(\sigma_i^2) + \log(P(\omega_i))$$

- ▶ elle ne peut pas être simplifiée ultérieurement.
- ▶ Les frontières de décision sont des fonctions quadriques : des hyper-ellipses

Navigation icons: back, forward, search, etc.



Cas 4 : $\Sigma_i = \sigma_i^2 I$ - Exemple

- ▶ illustration pour un cas à trois classes et 2 dimensions :

$$\mu_1 = (3 \ 2)^T \quad \mu_2 = (5 \ 4)^T \quad \mu_3 = (2 \ 5)^T$$

$$\Sigma_1 = \begin{pmatrix} 0.5 & 0 \\ 0 & 0.5 \end{pmatrix}, \quad \Sigma_2 = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \quad \text{et}$$

$$\Sigma_3 = \begin{pmatrix} 2 & 0 \\ 0 & 2 \end{pmatrix}$$



Navigation icons: back, forward, search, etc.

cas 5 : le cas général $\Sigma_i \neq \Sigma_j$

- ▶ la fonction discriminante est

$$g_i(\mathbf{x}) = -\frac{1}{2}(\mathbf{x} - \mu_i)^T \Sigma_i^{-1} (\mathbf{x} - \mu_i) - \frac{1}{2} \log(|\Sigma_i|) + \log(P(\omega_i))$$

- ▶ que l'on peut ré-organiser sous une forme quadratique

$$g_i(\mathbf{x}) = \mathbf{x}^T \mathbf{W}_i \mathbf{x} + \mathbf{w}_i^T \mathbf{x} + w_{i,0}$$

avec

$$\begin{aligned} \mathbf{W}_i &= -\frac{1}{2} \Sigma_i^{-1} \\ \mathbf{w}_i &= \Sigma_i^{-1} \mu_i \\ w_{i,0} &= -\frac{1}{2} \mu_i^T \Sigma_i^{-1} \mu_i - \frac{1}{2} \log(|\Sigma_i|) + \log(P(\omega_i)) \end{aligned}$$

- ▶ les frontières de décision sont des quadriques

Navigation icons: back, forward, search, etc.



Cas 5 : $\Sigma_i \neq \Sigma_j$ -Exemple

- ▶ illustration pour un cas à trois classes et 2 dimensions :

$$\mu_1 = (3 \ 2)^T \quad \mu_2 = (5 \ 4)^T \quad \mu_3 = (2 \ 5)^T$$

$$\Sigma_1 = \begin{pmatrix} 1 & -1 \\ -1 & 2 \end{pmatrix}, \quad \Sigma_2 = \begin{pmatrix} 1 & -1 \\ -1 & 7 \end{pmatrix} \text{ et}$$

$$\Sigma_3 = \begin{pmatrix} 0.5 & 0.5 \\ 0.5 & 3 \end{pmatrix}$$



Navigation icons: back, forward, search, etc.

Exemple numérique

- ▶ Calculer la fonction de décision linéaire du problème à 2 classes définis par des lois normales

$$\mu_1 = (0 \ 0 \ 0)^T \quad \mu_2 = (1 \ 1 \ 1)^T \quad \Sigma_1 = \Sigma_2 = \begin{pmatrix} 1/4 & 0 & 0 \\ 0 & 1/4 & 0 \\ 0 & 0 & 1/4 \end{pmatrix}$$

avec $P(\omega_1) = 2P(\omega_2)$

$$g(x) = -\frac{1}{2\sigma^2}(x-\mu_1)^T(x-\mu_1) + \log P(\omega_1) = -\frac{1}{2} \begin{bmatrix} x-\mu_x \\ y-\mu_y \\ z-\mu_z \end{bmatrix}^T \begin{bmatrix} 4 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 4 \end{bmatrix} \begin{bmatrix} x-\mu_x \\ y-\mu_y \\ z-\mu_z \end{bmatrix} + \log P(\omega_1)$$

$$g_1(x) = -\frac{1}{2} \begin{bmatrix} x-0 \\ y-0 \\ z-0 \end{bmatrix}^T \begin{bmatrix} 4 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 4 \end{bmatrix} \begin{bmatrix} x-0 \\ y-0 \\ z-0 \end{bmatrix} + \log \frac{1}{3}; \quad g_2(x) = -\frac{1}{2} \begin{bmatrix} x-1 \\ y-1 \\ z-1 \end{bmatrix}^T \begin{bmatrix} 4 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 4 \end{bmatrix} \begin{bmatrix} x-1 \\ y-1 \\ z-1 \end{bmatrix} + \log \frac{2}{3}$$

$$g_1(x) \underset{\omega_2}{>} \underset{\omega_1}{<} g_2(x) \Rightarrow -2(x^2 + y^2 + z^2) + \log \frac{1}{3} \underset{\omega_2}{>} \underset{\omega_1}{<} -2((x-1)^2 + (y-1)^2 + (z-1)^2) + \log \frac{2}{3}$$

$$\boxed{x + y + z \underset{\omega_1}{>} \underset{\omega_2}{<} \frac{6 - \log 2}{4} = 1.32}$$

- ▶ catégoriser l'exemple $x = [0.1 \ 0.7 \ 0.8]^T$

Navigation icons: back, forward, search, etc.

Conclusions

- ▶ pour des classes suivant une loi normale, en général la fonction de décision est quadratique
- ▶ pour des classes suivant une loi normale de matrice de **covariance identique**, la fonction de décision est linéaire
- ▶ des classifieurs très simples comme le classifieur à distance à la moyenne minimum est optimale dans certaines situations.
- ▶ Les hypothèses pour lesquels ces classifieurs sont optimales sont parfois difficile à vérifier. La question que l'on se pose alors est : " est ce que ce classifieur résoud mon problème ?"

Navigation icons: back, forward, search, etc.