

Distributions normales

Thierry Chateau

Pascal Institute

2017



Plan

- 1 Introduction
- 2 Expression de la loi normale
- 3 Distance de Mahalanobis
- 4 Fonctions discriminantes
- 5 Règles de décision
- 6 Exercice

- Les classifieurs Bayesiens sont basés sur des fonctions de densité de probabilité ($p(\mathbf{x}|\omega_i)$)
- Si $p(\mathbf{x}|\omega_i)$ est trop complexe, les temps de calcul sont élevés (intégrales présentes dans la formule de Bayes)
- D'où l'idée de modéliser $p(\mathbf{x}|\omega_i)$ par une fonction analytique définie avec seulement quelques paramètres
- La fonction la plus souvent utilisée est une loi normale (ou loi de Gauss) :
 - utilisée dans de nombreuses applications,
 - permet de modéliser de manière naturelle des caractéristiques bruitées aléatoirement
 - s'applique lorsque, pour une classe, les vecteurs \mathbf{x} sont répartis de manière continue et "harmonieuse" autour d'un vecteur moyen μ

Rappels : espérance, variance

- Soit $p(x)$ une densité de probabilités et $f(x)$ une fonction scalaire
- L'espérance de $f(x)$, pour la densité de probabilités $p(x)$ est définie par :

$$E[f(x)] = \int_{-\infty}^{\infty} f(x)p(x)dx$$

- L'espérance de x est appelée **moyenne** :

$$\mu = E[x] = \int_{-\infty}^{\infty} xp(x)dx$$

- L'espérance de la déviation quadratique $(x - \mu)^2$ est appelée variance :


$$= E[(x - \mu)^2] = \int_{-\infty}^{\infty} (x - \mu)^2 p(x)dx$$

Loi normale de dimension 1

Loi normale de dimension 1, notée $N(\mu, \sigma^2)$:

$$p(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp \left[-\frac{1}{2} \left(\frac{x - \mu}{\sigma} \right)^2 \right]$$

- μ : moyenne
- σ^2 : variance
- Max. de la courbe :
 $p(\mu) = 1/\sqrt{2\pi}\sigma$



- Loi normale généralisée à d dimensions et notée $N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$:

$$p(\mathbf{x}) = \frac{1}{(2\pi)^{d/2} |\boldsymbol{\Sigma}|^{1/2}} \exp \left[-\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}) \right]$$

$\boldsymbol{\mu}$: vecteur moyen

$$\boldsymbol{\mu} = E[\mathbf{x}] = \int \mathbf{x} p(\mathbf{x}) d\mathbf{x}$$

$$\mu_i = E[x_i]$$

Σ : matrice de covariance

$$\Sigma = E[(\mathbf{x} - \boldsymbol{\mu})(\mathbf{x} - \boldsymbol{\mu})']$$

$$\Sigma = \int (\mathbf{x} - \boldsymbol{\mu})(\mathbf{x} - \boldsymbol{\mu})' p(\mathbf{x}) d\mathbf{x}$$

$$\sigma_{ij} = E[(x_i - \mu_i)(x_j - \mu_j)]$$

Dans le cas discret :

$$\sigma_{ij} = \frac{1}{N} \sum_x (x_i - \mu_i)(x_j - \mu_j)$$

La matrice de covariance

- Σ contient toute l'information sur la façon dont se répartissent les formes de la classe dans l'espace des paramètres.
- Σ décrit la dispersion des données
- Σ est symétrique ($\sigma_{ij} = \sigma_{ji}$)
- si les composantes du vecteur de paramètres sont statistiquement indépendantes (x_i et x_j), alors $\sigma_{ij} = \sigma_{ji} = 0 \ i \neq j$.


- Les courbes de densité de probabilité constantes sont modélisées par des hyperboloïdes d'équation

$$(\mathbf{x} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}) = c, \text{ avec } c \in \mathbb{R}$$

- Les directions des axes principaux sont définies par les valeurs propres
- La dispersion selon chaque axe principal est déterminée par la valeur propre correspondante
- La distance de Mahalanobis entre un vecteur de paramètres \mathbf{x} et $\boldsymbol{\mu}$ est définie par :

$$\sqrt{(\mathbf{x} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu})}$$

Exemple dans R^2



Distance de Mahalanobis

Volume de l'hyper-ellipsoïde défini une distance de Mahalanobis de r :

$$V = V_d |\Sigma|^{-1/2} r^d$$

avec V_d : volume de l'hypersphère unité :

$$d \text{ pair} \rightarrow V_d = \frac{\pi^{d/2}}{(d/2)!}$$

$$d \text{ impair} \rightarrow V_d = \frac{2^d \pi^{(d-1)/2} \left(\frac{d-1}{2} \right)!}{d!}$$

Il est possible de définir des fonctions discriminantes spécifiquement associées à une loi normale :

$$g_{\omega_i} = \log(p(\mathbf{x}|\omega_i)) + \log(P(\omega_i))$$

Dans l'hypothèse d'une loi normale pour ω_i : $N(\boldsymbol{\mu}_{\omega_i}, \boldsymbol{\Sigma}_{\omega_i})$

$$g_{\omega_i} = -\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_{\omega_i})^t \boldsymbol{\Sigma}_{\omega_i}^{-1} (\mathbf{x} - \boldsymbol{\mu}_{\omega_i}) - \frac{d}{2} \log(2\pi) - \frac{1}{2} \log |\boldsymbol{\Sigma}_{\omega_i}| + \log(p(\omega_i))$$

Fonction complexe mais souvent simplifiable


Cas 1 : $\Sigma_{\omega_i} = \sigma^2 \mathbf{I}$

$$\Sigma_{\omega_i} = \begin{pmatrix} \sigma^2 & 0 & \cdot & 0 \\ 0 & \sigma^2 & \cdot & 0 \\ \cdot & \cdot & \cdot & 0 \\ 0 & \cdot & 0 & \sigma^2 \end{pmatrix} \quad (1)$$

Pour toutes les classes, la variance de chaque composante du vecteur de paramètres est identique. De plus, \mathbf{x}_i et \mathbf{x}_j sont statistiquement indépendants.

Cas 1 : $\Sigma_{\omega_i} = \sigma^2 \mathbf{I}$

Les classes résultantes ont la forme d'une hyper-shère



Cas 1 : fonction discriminante

Les termes de la fonction discriminante se simplifient :

$$|\Sigma_{\omega_i}| = \sigma^{2d}$$

Ce terme ne dépend plus de ω_i .

D'où la fonction discriminante :

$$g_{\omega_i} = -\frac{\|\mathbf{x} - \boldsymbol{\mu}_{\omega_i}\|^2}{2\sigma^2} + \log(P(\omega_i))$$

avec :

$$\|\mathbf{x} - \boldsymbol{\mu}_{\omega_i}\|^2 = (\mathbf{x} - \boldsymbol{\mu}_{\omega_i})^t (\mathbf{x} - \boldsymbol{\mu}_{\omega_i})$$

carré de la distance Euclidienne


Cas 1 : fonction discriminante

Si les classes sont equiprobables :

$$g_{\omega_i} = -(\mathbf{x} - \boldsymbol{\mu}_{\omega_i})^t(\mathbf{x} - \boldsymbol{\mu}_{\omega_i})$$


Cas 1 : règle de décision

Pour une observation \mathbf{x} , la classe choisie sera celle dont le centre sera le plus proche (distance euclidienne) : **classifieur de distance minimum**



Cas 1 : règle de décision

Cas de 4 classes



Cas 1 : $P(\omega_i) \neq P(\omega_j)$

L'expression de la fonction devient :

$$g_{\omega_i}(\mathbf{x}) = \frac{1}{2\sigma} [\mathbf{x}^t \mathbf{x} - 2\boldsymbol{\mu}_i^t \mathbf{x} + \boldsymbol{\mu}_i^t \boldsymbol{\mu}_i] + \log(P(\omega_i))$$

On peut montrer que cela s'écrit également :

$$g_{\omega_i}(\mathbf{x}) = \mathbf{K}_i^t \mathbf{x} + K_{i0}$$

avec

$$\mathbf{K}_i = \frac{1}{\sigma^2}$$

et

$$K_{i0} = -\frac{1}{2\sigma^2} \boldsymbol{\mu}_i^t \boldsymbol{\mu}_i + \log(P(\omega_i))$$

Cas 1 : $P(\omega_i) \neq P(\omega_j)$

$$g_{\omega_i}(\mathbf{x}) = \mathbf{K}_i^t \mathbf{x} + K_{i0}$$

C'est une fonction linéaire \rightarrow les surfaces de décision sont donc des hyperplans d'équation (entre R_i et j):

$$g_{\omega_i}(\mathbf{x}) = g_{\omega_j}(\mathbf{x}) \rightarrow g_{\omega_i}(\mathbf{x}) - g_{\omega_j}(\mathbf{x}) = 0$$

soit

$$(\mathbf{K}_i^t \mathbf{x} + K_{i0}) - (\mathbf{K}_j^t \mathbf{x} + K_{j0}) = 0$$

Cas 1 : $P(\omega_i) \neq P(\omega_j)$

Cette equation peut s'écrire :

$$\mathbf{W}^t(\mathbf{x} - \mathbf{x}_0) = 0$$

avec :


$$\mathbf{W} = \boldsymbol{\mu}_{\omega_i} - \boldsymbol{\mu}_{\omega_j}$$

et

$$\mathbf{x}_0 = \frac{1}{2}(\boldsymbol{\mu}_{\omega_i} + \boldsymbol{\mu}_{\omega_j}) - \frac{\sigma^2}{\|\boldsymbol{\mu}_{\omega_i} - \boldsymbol{\mu}_{\omega_j}\|} \log\left(\frac{P(\omega_i)}{P(\omega_j)}\right) (\boldsymbol{\mu}_{\omega_i} - \boldsymbol{\mu}_{\omega_j})$$


Cas 1 : $P(\omega_i) \neq P(\omega_j)$

C'est l'équation d'un hyperplan perpendiculaire à \mathbf{W} et passant par \mathbf{x}_0



Cas 1 : $P(\omega_i) = P(\omega_j)$

$$P(\omega_i) = P(\omega_j)$$




Cas 1 : $P(\omega_i) \neq P(\omega_j)$

si $\sigma^2 \ll \|\mathbf{mu}_{\omega_i} - \mathbf{mu}_{\omega_j}\|^2$ alors $P(\omega_i)$ et (ω_j) influent peu et :

$$\mathbf{x}_0 \approx \frac{1}{2}(\mathbf{mu}_{\omega_i} - \mathbf{mu}_{\omega_j})$$

Cas 2 : $\Sigma_i = \Sigma_j$

Toutes les classes ont la même matrice de covariance :



Cas 2 : $\Sigma_i = \Sigma_j$

Fonction discriminante de départ :

$$g_{\omega_i} = -\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_{\omega_i})^t \Sigma_{\omega_i}^{-1} (\mathbf{x} - \boldsymbol{\mu}_{\omega_i}) - \frac{d}{2} \log(2\pi) - \frac{1}{2} \log |\Sigma_{\omega_i}| + \log(p(\omega_i))$$

Supprimons les termes indépendants de i :

$$g_{\omega_i} = -\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_{\omega_i})^t \Sigma_{\omega_i}^{-1} (\mathbf{x} - \boldsymbol{\mu}_{\omega_i}) + \log(p(\omega_i))$$

avec

$$(\mathbf{x} - \boldsymbol{\mu}_{\omega_i})^t \Sigma_{\omega_i}^{-1} (\mathbf{x} - \boldsymbol{\mu}_{\omega_i})$$

distance de Mahalanobis de la forme \mathbf{x} à la moyenne de la classe $\boldsymbol{\mu}_{\omega_i}$

Cas 2 : $\Sigma_i = \Sigma_j$

La frontière entre deux formes est définie par : $g(\mathbf{x}) = (g_{\omega_i}(\mathbf{x}) - g_{\omega_j}(\mathbf{x})) = 0$; Soit l'équation d'un hyperplan :

$$\mathbf{W}^t(\mathbf{x} - \mathbf{x}_0) = 0$$

On obtient, après quelques calculs :

$$\mathbf{W} = \Sigma^{-1}(\boldsymbol{\mu}_{\omega_i} - \boldsymbol{\mu}_{\omega_j})$$
$$\mathbf{x}_0 = \frac{1}{2}(\boldsymbol{\mu}_{\omega_i} + \boldsymbol{\mu}_{\omega_j}) - \frac{\log\left(\frac{P(\omega_i)}{P(\omega_j)}\right)}{(\boldsymbol{\mu}_{\omega_i} - \boldsymbol{\mu}_{\omega_j})^t \Sigma^{-1}(\boldsymbol{\mu}_{\omega_i} - \boldsymbol{\mu}_{\omega_j})}(\boldsymbol{\mu}_{\omega_i} - \boldsymbol{\mu}_{\omega_j})$$


Cas 2 : $\Sigma_i = \Sigma_j$

Remarques :

- \mathbf{W} n'est pas forcément dans la direction $\boldsymbol{\mu}_{\omega_i} - \boldsymbol{\mu}_{\omega_j}$
- L'hyperplan séparateur n'est donc pas forcément perpendiculaire à $\boldsymbol{\mu}_{\omega_i} - \boldsymbol{\mu}_{\omega_j}$
- si $P(\omega_i) = P(\omega_j)$, l'hyperplan passe par le milieu du segment qui joint les extrémités des vecteurs $\boldsymbol{\mu}_{\omega_i}$ et $\boldsymbol{\mu}_{\omega_j}$

Cas 2 : $\Sigma_i = \Sigma_j$

$$P(\omega_i) = P(\omega_j)$$



Cas 3 : matrices de cov. distinctes

Forme générale des fonctions discriminantes :

$$g_{\omega_i} = -\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_{\omega_i})^t \boldsymbol{\Sigma}_{\omega_i}^{-1} (\mathbf{x} - \boldsymbol{\mu}_{\omega_i}) - \frac{d}{2} \log(2\pi) - \frac{1}{2} \log |\boldsymbol{\Sigma}_{\omega_i}| + \log(p(\omega_i))$$

Seul $\frac{d}{2} \log(2\pi)$ peut être éliminé. On obtient une fonction du second degré en \mathbf{x} de la forme :

$$g_{\omega_i}(\mathbf{x}) = \mathbf{x}^t \mathbf{W}_1 \mathbf{x} + \mathbf{W}_2^t \mathbf{x} + \mathbf{W}_3$$

Cas 3 : matrices de cov. distinctes

$$g_{\omega_i}(\mathbf{x}) = \mathbf{x}^t \mathbf{W}_1 \mathbf{x} + \mathbf{W}_2^t \mathbf{x} + \mathbf{W}_3$$

avec :

$$\mathbf{W}_1 = -\frac{1}{2} \Sigma_{\omega_i}^{-1} \mathbf{1}$$

$$\mathbf{W}_2 = \Sigma_{\omega_i}^{-1} \mathbf{1} \mu_{\omega_i}$$


$$\mathbf{W}_3 = -\frac{1}{2} \mu_{\omega_i}^t \Sigma_{\omega_i}^{-1} \mathbf{1} \mu_{\omega_i} - \frac{1}{2} \log(|\Sigma_{\omega_i}|) + \log(P(\omega_i))$$

Cas 3 : matrices de cov. distinctes


Les surfaces de décision obtenues sont des hyperquadratiques :

- paire d'hyperplans
- hypersphères
- hyperellipsoïdes
- hyperhyperboloïdes

exemples de frontières




$$\Sigma_{\omega_i} = \Sigma_{\omega_j} = \sigma^2 \mathbf{I}$$




Cas1 :

exemples de frontières




$$\Sigma_{\omega_i} = \Sigma_{\omega_j}$$




Cas2 :

exemples de frontières




Quelconque




Cas3 :

exemples de frontières



Quelconque



Cas3 :

- Hypothèse restrictive : toutes les classes suivent une loi gaussienne
- Ce n'est pas toujours (souvent) le cas.
- Il est alors possible de découper la classe en 2 deux sous-classes qui correspondent mieux à des lois normales.

Exercice : Classification Bayésienne

- 1 Soient deux classes suivant des lois normales et de probabilités a priori $P(C1) = P(C2) = 0.5$. On supposera que les formes sont des vecteurs de \mathcal{R}^2 et que :

$$\mu_{C1} = \begin{pmatrix} 1 \\ 0 \end{pmatrix}, \mu_{C2} = \begin{pmatrix} -1 \\ 0 \end{pmatrix}; \Sigma_{C1} = \begin{pmatrix} 1 & 0.5 \\ 0.5 & 1 \end{pmatrix}, \Sigma_{C2} = \begin{pmatrix} 4 & 2 \\ \frac{3}{2} & \frac{4}{3} \\ -\frac{3}{2} & \frac{4}{3} \end{pmatrix}$$

Calculer la distance de Mahalanobis entre la forme $\begin{pmatrix} 0 \\ 0 \end{pmatrix}$ et chaque classe

Pour info :

$$\Sigma_{C1}^{-1} = \begin{pmatrix} 4 & 2 \\ \frac{3}{2} & \frac{4}{3} \\ -\frac{3}{2} & \frac{4}{3} \end{pmatrix}, \Sigma_{C2}^{-1} = \begin{pmatrix} 1 & 0.5 \\ 0.5 & 1 \end{pmatrix}$$

- 2 Donner la forme de l'équation de la frontière de décision bayésienne entre les deux classes