

Classification supervisée et non supervisée: Point de vue des Modèles de mélange Gaussien

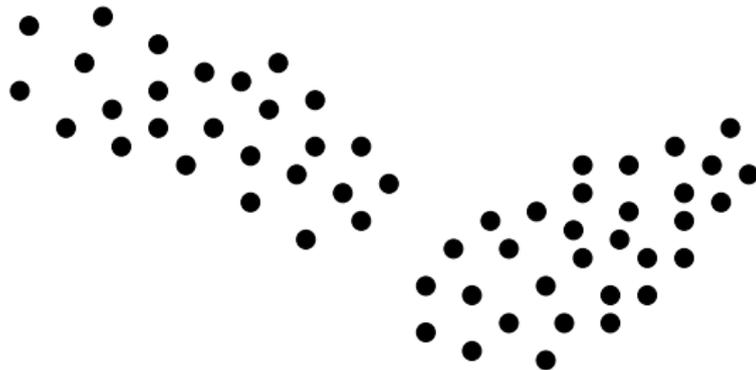
Nicolas Verzelen

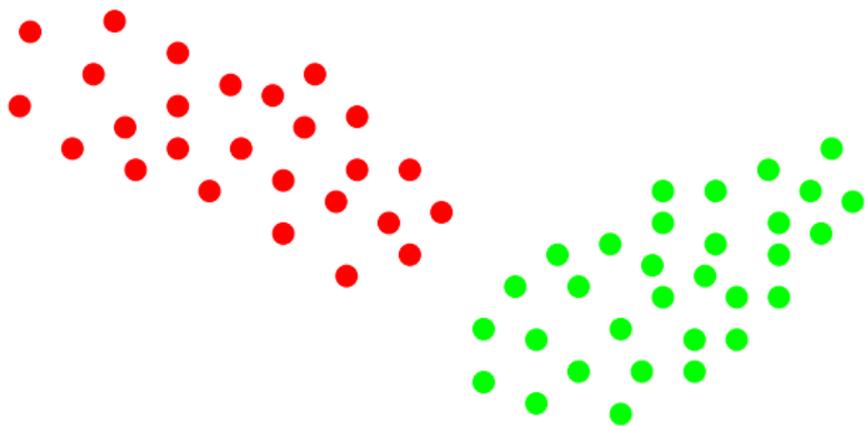
INRA, Montpellier

Travail commun avec

Ery Arias-Castro

UC San Diego





k : nombre de classes

$\nu \in [0, 1]^k$ tel que $\sum_{i=1}^k \nu_i = 1$: poids du mélange

$\forall i \in \{1, \dots, K\}$, $\mu_i \in \mathbb{R}^p$ et $\Sigma_i \in \mathcal{S}^+(p)$.

Modèles de Mélange Gaussien

k : nombre de classes

$\nu \in [0, 1]^k$ tel que $\sum_{i=1}^k \nu_i = 1$: poids du mélange

$\forall i \in \{1, \dots, k\}$, $\mu_i \in \mathbb{R}^p$ et $\Sigma_i \in \mathcal{S}^+(p)$.

Loi de $(X, Z) \in \mathbb{R}^p \times \{1, \dots, k\}$:

$Z \sim \mathcal{M}(\nu)$

$X|Z \sim \mathcal{N}(\mu_Z, \Sigma_Z)$

Loi **Marginale** : $X \sim f$ avec $f = \sum_{i=1}^k \nu_i \phi(\mu_i, \Sigma_i)$

k : nombre de classes

$\nu \in [0, 1]^k$ tel que $\sum_{i=1}^k \nu_i = 1$: poids du mélange

$\forall i \in \{1, \dots, K\}$, $\mu_i \in \mathbb{R}^p$ et $\Sigma_i \in \mathcal{S}^+(p)$.

Loi de $(X, Z) \in \mathbb{R}^p \times \{1, \dots, k\}$:

$Z \sim \mathcal{M}(\nu)$

$X|Z \sim \mathcal{N}(\mu_Z, \Sigma_Z)$

Loi **Marginale** : $X \sim f$ avec $f = \sum_{i=1}^k \nu_i \phi(\mu_i, \Sigma_i)$

Données :

- 1 Échantillon supervisé $(X_1, Z_1), \dots, (X_n, Z_n)$.
- 2 Échantillon non supervisé (X_1, \dots, X_n) .

Échantillon supervisé :

- Estimation des paramètres μ_i, Σ_i
- Classification
- Sélection de structure différenciant les classes
- Test d'homogénéité : $\mu_1 = \dots = \mu_k, \Sigma_1 = \dots = \Sigma_k$.

Échantillon supervisé :

- Estimation des paramètres μ_i, Σ_i
- Classification
- Sélection de structure différenciant les classes
- Test d'homogénéité : $\mu_1 = \dots = \mu_k, \Sigma_1 = \dots = \Sigma_k$.

Échantillon non supervisé :

- Estimation des paramètres des composantes
- Estimation de densité f .
- Clustering ; Classification
- Sélection de structure différenciant les classes
- Test d'homogénéité

Quelques questions :

- Quelle est la difficulté "intrinsèque" de chacun des problèmes?

Quelques questions :

- Quelle est la difficulté “intrinsèque” de chacun des problèmes?
- Quelle différence entre cas supervisé et cas non supervisé?

Quelques questions :

- Quelle est la difficulté "intrinsèque" de chacun des problèmes?
- Quelle différence entre cas supervisé et cas non supervisé?
- Quel est l'effet de la présence de structure?

Quelques questions :

- Quelle est la difficulté “intrinsèque” de chacun des problèmes ?
- Quelle différence entre cas supervisé et cas non supervisé ?
- Quel est l'effet de la présence de structure ?
- Que peut-on faire en temps polynomial ?

Quelques questions :

- Quelle est la difficulté “intrinsèque” de chacun des problèmes ?
- Quelle différence entre cas supervisé et cas non supervisé ?
- Quel est l'effet de la présence de structure ?
- Que peut-on faire en temps polynomial ?

Cadre statistique

- Cas de petite ($p \ll n$) ou grande dimension ($p \gg n$).
- Possiblement de la structure (parcimonie)

Quelques questions :

- Quelle est la difficulté “intrinsèque” de chacun des problèmes ?
- Quelle différence entre cas supervisé et cas non supervisé ?
- Quel est l'effet de la présence de structure ?
- Que peut-on faire en temps polynomial ?

Cadre statistique

- Cas de petite ($p \ll n$) ou grande dimension ($p \gg n$).
- Possiblement de la structure (parcimonie)

Estimation des composantes

Estimation de la densité

Estimation des composantes $\mu_i, \Sigma_i \rightsquigarrow$ problème d'estimation paramétrique

Sans hypothèse de structure : Vitesse d'estimation (ex Kullback) en $\frac{p+(p+1)p/2}{\nu_i n}$.

Estimation des composantes $\mu_i, \Sigma_i \rightsquigarrow$ problème d'estimation paramétrique

Sans hypothèse de structure : Vitesse d'estimation (ex Kullback) en $\frac{p+(p+1)p/2}{\nu_i n}$.

Estimation simultanée de moyennes et covariance avec présence de structure :
parcimonie de μ , parcimonie de Σ^{-1}, \dots

pénalisation l_1 , Glasso d'Aspremont et al. (2006), Raskutti et al (2011)

Estimation des composantes $\mu_i, \Sigma_i \rightsquigarrow$ problème d'estimation paramétrique

Sans hypothèse de structure : Vitesse d'estimation (ex Kullback) en $\frac{p+(p+1)p/2}{\nu_i n}$.

Estimation simultanée de moyennes et covariance avec présence de structure : parcimonie de μ , parcimonie de Σ^{-1}, \dots

pénalisation l_1 , Glasso d'Aspremont et al. (2006), Raskutti et al (2011)

Estimation de la densité du mélange

Lemme (Genovese et Wasserman (2000))

Soient $f = \sum_{i=1}^k a_i f_i$ et $g = \sum_{i=1}^k b_i g_i$ deux mélanges. On a

$$d_H^2(f, g) \leq \sum_{i=1}^k d_H^2(a_i f_i, b_i g_i) ,$$

Estimation des composantes $\mu_i, \Sigma_i \rightsquigarrow$ problème d'estimation paramétrique

Sans hypothèse de structure : Vitesse d'estimation (ex Kullback) en $\frac{p+(p+1)p/2}{\nu_i n}$.

Estimation simultanée de moyennes et covariance avec présence de structure : parcimonie de μ , parcimonie de Σ^{-1}, \dots

pénalisation l_1 , **Glasso d'Aspremont et al. (2006), Raskutti et al (2011)**

Estimation de la densité du mélange

Lemme (Genovese et Wasserman (2000))

Soient $f = \sum_{i=1}^k a_i f_i$ et $g = \sum_{i=1}^k b_i g_i$ deux mélanges. On a

$$d_H^2(f, g) \leq \sum_{i=1}^k d_H^2(a_i f_i, b_i g_i) ,$$

Première conséquence : contrôle de l'erreur en estimation de densité.

$$\mathbb{E}[d_H^2(\hat{f}, f)] \lesssim \sum_{i=1}^k \frac{p^2 \nu_i}{\nu_i n} \lesssim \frac{kp^2}{n}$$

$$\mathcal{L}(x_1, \dots, x_n) = \sum_{i=1}^n \log \left[\sum_{i=1}^k \nu_i \phi(\mu_i, \Sigma_i) \right]$$

Maximisation de la vraisemblance \rightsquigarrow Algorithme EM.

$$\mathcal{L}(x_1, \dots, x_n) = \sum_{i=1}^n \log \left[\sum_{i=1}^k \nu_i \phi(\mu_i, \Sigma_i) \right]$$

Maximisation de la vraisemblance \rightsquigarrow Algorithme EM.

$$\text{Rappel : } d_H^2(f, g) \leq \sum_{i=1}^k d_H^2(a_i f_i, b_i g_i),$$

2e conséquence : contrôle de l'entropie d'une classe de mélange

Genovese et Wasserman (2000), Ghosal et Van der Vaart (2001), Maugis et Michel (2011)

$$\mathbb{E}[d_H^2(\hat{f}, f)] \lesssim \frac{kp^2}{n}$$

- + Inégalités oracle, adaptation à k
- + Pénalisation l_0 : Maugis et Michel (2011)

$$\mathcal{L}(x_1, \dots, x_n) = \sum_{i=1}^n \log \left[\sum_{i=1}^k \nu_i \phi(\mu_i, \Sigma_i) \right]$$

Maximisation de la vraisemblance \rightsquigarrow Algorithme EM.

$$\text{Rappel : } d_H^2(f, g) \leq \sum_{i=1}^k d_H^2(a_i f_i, b_i g_i),$$

2e conséquence : contrôle de l'entropie d'une classe de mélange

Genovese et Wasserman (2000), Ghosal et Van der Vaart (2001), Maugis et Michel (2011)

$$\mathbb{E}[d_H^2(\hat{f}, f)] \lesssim \frac{kp^2}{n}$$

- + Inégalités oracle, adaptation à k
- + Pénalisation l_0 : Maugis et Michel (2011)

Prise en compte de structure par pénalisation de type l_1 : Städler, Bühlmann, et van de Geer (2010) Xie, Pan et Chen (2008)

\rightsquigarrow Peu de résultats théoriques.

$$\mathcal{L}(x_1, \dots, x_n) = \sum_{i=1}^n \log \left[\sum_{i=1}^k \nu_i \phi(\mu_i, \Sigma_i) \right]$$

Maximisation de la vraisemblance \rightsquigarrow Algorithme EM.

$$\text{Rappel : } d_H^2(f, g) \leq \sum_{i=1}^k d_H^2(a_i f_i, b_i g_i),$$

2e conséquence : contrôle de l'entropie d'une classe de mélange

Genovese et Wasserman (2000), Ghosal et Van der Vaart (2001), Maugis et Michel (2011)

$$\mathbb{E}[d_H^2(\hat{f}, f)] \lesssim \frac{kp^2}{n}$$

- + Inégalités oracle, adaptation à k
- + Pénalisation l_0 : Maugis et Michel (2011)

Prise en compte de structure par pénalisation de type l1 : Städler, Bühlmann, et van de Geer (2010) Xie, Pan et Chen (2008)

\rightsquigarrow Peu de résultats théoriques.

Point de vue Computer science : Complexité de la maximisation de vraisemblance ?
Aucun algorithme polynomial connu à ce jour.

Estimation non supervisé des composantes ?

Identifiabilité : **Teicher (1961)** Si (μ_i, Σ_i) sont 2 à 2 distincts, alors le modèle est identifiable (à permutation près)

Estimation non supervisé des composantes ?

Identifiabilité : **Teicher (1961)** Si (μ_i, Σ_i) sont 2 à 2 distincts, alors le modèle est identifiable (à permutation près)

Objectif : Trouver un estimateur $(\nu_i, \hat{\mu}_i, \hat{\Sigma}_i)$ tel que pour une permutation π

$$\sum_{i=1}^k d \left[\phi(\mu_i, \Sigma_i), \phi(\hat{\mu}_{\pi(i)}, \hat{\Sigma}_{\pi(i)}) \right] \text{ petit (ex : } < \epsilon \text{ fixé).}$$

Identifiabilité robuste : $\kappa(f) := \min(\nu_i) \wedge \min \|\phi(\mu_i, \Sigma_i) - \phi(\mu_j, \Sigma_j)\|_{TV} > 0$

Estimation non supervisé des composantes ?

Identifiabilité : **Teicher (1961)** Si (μ_i, Σ_i) sont 2 à 2 distincts, alors le modèle est identifiable (à permutation près)

Objectif : Trouver un estimateur $(\nu_i, \hat{\mu}_i, \hat{\Sigma}_i)$ tel que pour une permutation π

$$\sum_{i=1}^k d \left[\phi(\mu_i, \Sigma_i), \phi(\hat{\mu}_{\pi(i)}, \hat{\Sigma}_{\pi(i)}) \right] \text{ petit (ex : } < \epsilon \text{ fixé).}$$

Identifiabilité robuste : $\kappa(f) := \min(\nu_i) \wedge \min \|\phi(\mu_i, \Sigma_i) - \phi(\mu_j, \Sigma_j)\|_{TV} > 0$

Proposition (Une minoration **Moltra et Valiant (2010)**)

Il existe deux modèles de modèle de mélange f, f' avec k composantes :

- f et f' satisfont $\kappa(f) \geq 1/k$ et $\kappa(f') > 1/k$.
- $\min_{\pi} \min_i \|\phi(\mu_i, \Sigma_i) - \phi(\mu'_{\pi(i)}, \Sigma'_{\pi(i)})\|_{TV} \geq 1/4$
- $\|f - f'\|_{TV} \leq O(e^{-k/30})$.

Conséquence : lorsque le nombre de composantes k est grand, n doit être exponentiellement grand.

- Clustering puis estimation : Dasgupta (1999)

Condition : séparabilité importante $\|\mu_i - \mu_j\|^2 \gtrsim \sqrt{p} \max_s \lambda_{\max}(\Sigma_s)$

- Méthode spectrale (ie ACP-like) : Vempala, Wang (2004), Achlioptas McSherry (2005), Kannan, Salmasian, Sempala (2008)

Condition : séparabilité $\|\mu_i - \mu_j\|^2 \gtrsim [k + \sqrt{k \log(kp)}] \max_s \lambda_{\max}(\Sigma_s)$

Taille d'échantillon : $n \gg \frac{k(p + \log(k))}{\kappa(f)}$

- Clustering puis estimation : Dasgupta (1999)

Condition : séparabilité importante $\|\mu_i - \mu_j\|^2 \gtrsim \sqrt{p} \max_s \lambda_{\max}(\Sigma_s)$

- Méthode spectrale (ie ACP-like) : Vempala, Wang (2004), Achlioptas McSherry (2005), Kannan, Salmasian, Sempala (2008)

Condition : séparabilité $\|\mu_i - \mu_j\|^2 \gtrsim [k + \sqrt{k \log(kp)}] \max_s \lambda_{\max}(\Sigma_s)$

Taille d'échantillon : $n \gg \frac{k(p + \log(k))}{\kappa(f)}$

- Relaxation SDP du critère k -means Mixon, Villar, Ward (2016)

$\inf_{(A_t)} \sum_{i=1}^k \sum_{j \in A_i} \|x_j - \frac{1}{|A_i|} \sum_{l \in A_i} x_l\|_2^2$.

Condition clustering approx : séparabilité $\|\mu_i - \mu_j\|^2 \gtrsim k(k \wedge p) \max_s \lambda_{\max}(\Sigma_s)$

Taille d'échantillon : $n \gg p$.

- Clustering puis estimation : Dasgupta (1999)

Condition : séparabilité importante $\|\mu_i - \mu_j\|^2 \gtrsim \sqrt{p} \max_s \lambda_{\max}(\Sigma_s)$

- Méthode spectrale (ie ACP-like) : Vempala, Wang (2004), Achlioptas McSherry (2005), Kannan, Salmasian, Sempala (2008)

Condition : séparabilité $\|\mu_i - \mu_j\|^2 \gtrsim [k + \sqrt{k \log(kp)}] \max_s \lambda_{\max}(\Sigma_s)$

Taille d'échantillon : $n \gg \frac{k(p + \log(k))}{\kappa(f)}$

- Relaxation SDP du critère k -means Mixon, Villar, Ward (2016)

$\inf_{(A_t)} \sum_{i=1}^k \sum_{j \in A_i} \|x_j - \frac{1}{|A_i|} \sum_{l \in A_i} x_l\|_2^2$.

Condition clustering approx : séparabilité $\|\mu_i - \mu_j\|^2 \gtrsim k(k \wedge p) \max_s \lambda_{\max}(\Sigma_s)$

Taille d'échantillon : $n \gg p$.

- Méthode des moments Kalai, Moitra, Valiant (2010,2010,2014)

Condition : $n > \left(\frac{p}{\epsilon \kappa(f)}\right)^{c_k}$.

Basé sur les $4k - 2$ moments empiriques de projections de la distribution.

Classification

Test du nombre de composantes

Sélection de variables

$k = 2$ Classes. $\Sigma_0 = \Sigma_1$

$k = 2$ Classes. $\Sigma_0 = \Sigma_1$

$$X_i = \eta_i \mu_0 + (1 - \eta_i) \mu_1 + \Sigma^{1/2} Z_i ,$$

où $\eta_1, \dots, \eta_n \stackrel{\text{iid}}{\sim} \text{Bern}(\nu)$ et indépendant de $Z_1, \dots, Z_n \stackrel{\text{iid}}{\sim} \mathcal{N}(0, \mathbf{I})$.

$k = 2$ Classes. $\Sigma_0 = \Sigma_1$

$$X_i = \eta_i \mu_0 + (1 - \eta_i) \mu_1 + \Sigma^{1/2} Z_i ,$$

où $\eta_1, \dots, \eta_n \stackrel{\text{iid}}{\sim} \text{Bern}(\nu)$ et indépendant de $Z_1, \dots, Z_n \stackrel{\text{iid}}{\sim} \mathcal{N}(0, \mathbf{I})$.

$$X \sim \nu \mathcal{N}(\mu_0, \Sigma) + (1 - \nu) \mathcal{N}(\mu_1, \Sigma) .$$

Modèle proche de celui de l'analyse linéaire discriminante en classification supervisée.

Différence des moyennes : $\Delta\mu := \mu_1 - \mu_0$.

Soit $\psi : \mathbb{R}^p \mapsto \{0, 1\}$ un classifieur

$$l_{cl}(\psi) := \min_{\pi} \{ \mathbb{P}_0[\psi(X) = \pi(1)] + \mathbb{P}_1[\psi(X) = \pi(0)] \}$$

$$l_{\neq}(\psi) := 2 \mathbb{P}_{0,1}[\psi(X) = \psi(\tilde{X})] + \mathbb{P}_{0,0}[\psi(X) \neq \psi(\tilde{X})] \\ + \mathbb{P}_{1,1}[\psi(X) \neq \psi(\tilde{X})]$$

Soit $\psi : \mathbb{R}^p \mapsto \{0, 1\}$ un classifieur

$$l_{cl}(\psi) := \min_{\pi} \{ \mathbb{P}_0[\psi(X) = \pi(1)] + \mathbb{P}_1[\psi(X) = \pi(0)] \}$$

$$l_{\neq}(\psi) := 2 \mathbb{P}_{0,1}[\psi(X) = \psi(\tilde{X})] + \mathbb{P}_{0,0}[\psi(X) \neq \psi(\tilde{X})] \\ + \mathbb{P}_{1,1}[\psi(X) \neq \psi(\tilde{X})]$$

Lemme

Pour tout classifieur ψ ,

$$l_{\neq}(\psi) = 2l_{cl}(\psi)(2 - l_{cl}(\psi))$$

$$l_{sc}(\psi) := \mathbb{P}_0[\psi(X) = 1] + \mathbb{P}_1[\psi(X) = 0] \geq l_{cl}(\psi)$$

Étant donné un échantillon supervisé, le risque d'un classifieur supervisé est donné par

$$R_{sc}(\hat{\psi}) = \mathbb{E}_{(X_1, Z_1), \dots, (X_n, Z_n)} [l_{sc}(\hat{\psi})]$$

Proposition (Comparaison des risques minimax)

$$\inf_{\hat{\psi}_{[X_1, \dots, X_{n-1}]}} \sup_{f \in \mathcal{F}} R_{cl}(\hat{\psi}) \geq \frac{1}{3} \inf_{\hat{\psi}_{[(X_1, Z_1), \dots, (X_n, Z_n)]}} \sup_{f \in \mathcal{F}} R_{sc}(\hat{\psi}) .$$

Si $\nu = 1/2$, alors

$$\inf_{\hat{\psi}_{[X_1, \dots, X_{n-1}]}} \sup_{f \in \mathcal{F}} R_{\neq}(\hat{\psi}) \geq 2 \inf_{\hat{\psi}_{[(X_1, Z_1), \dots, (X_n, Z_n)]}} \sup_{f \in \mathcal{F}} R_{sc}(\hat{\psi}) .$$

Soit Π une distribution à priori sur une classe \mathcal{F} .

Pour $(i, j) \in \{0, 1\}^2$, $\mathbf{P}_{i,j}$ est la loi de $(X_1, \dots, X_n, X, \tilde{X})$ où :
 $(X_1, \dots, X_n) \sim f$, $X \sim \phi(\mu_i, \Sigma)$, $\tilde{X} \sim \phi(\mu_j, \Sigma)$.

Comparaison entre test d'homogénéité et classification

Soit Π une distribution à priori sur une classe \mathcal{F} .

Pour $(i, j) \in \{0, 1\}^2$, $\mathbf{P}_{i,j}$ est la loi de $(X_1, \dots, X_n, X, \tilde{X})$ où :
 $(X_1, \dots, X_n) \sim f$, $X \sim \phi(\mu_i, \Sigma)$, $\tilde{X} \sim \phi(\mu_j, \Sigma)$.

$$\mathbf{P}_{i,j}^{\Pi} := \int \mathbf{P}_{i,j} \Pi(df)$$

$\mathbf{P}^{(0)}$: loi d'un échantillon de $n + 2$ gaussiennes standards.

$$\begin{aligned} \sup_{f \in \mathcal{F}} R_{\neq}(\hat{\psi}) &\geq E_{\Pi}[R_{\neq}(\hat{\psi})] \\ &\geq 2 \left[1 - \left\| \frac{1}{2} (\mathbf{P}_{0,1}^{\Pi} + \mathbf{P}_{1,0}^{\Pi}) - \mathbf{P}^{(0)} \right\|_{TV} - \left\| \frac{1}{2} (\mathbf{P}_{0,0}^{\Pi} + \mathbf{P}_{1,1}^{\Pi}) - \mathbf{P}^{(0)} \right\|_{TV} \right] \end{aligned}$$

Comparaison entre test d'homogénéité et classification

Soit Π une distribution à priori sur une classe \mathcal{F} .

Pour $(i, j) \in \{0, 1\}^2$, $\mathbf{P}_{i,j}$ est la loi de $(X_1, \dots, X_n, X, \tilde{X})$ où :
 $(X_1, \dots, X_n) \sim f$, $X \sim \phi(\mu_i, \Sigma)$, $\tilde{X} \sim \phi(\mu_j, \Sigma)$.

$$\mathbf{P}_{i,j}^{\Pi} := \int \mathbf{P}_{i,j} \Pi(df)$$

$\mathbf{P}^{(0)}$: loi d'un échantillon de $n + 2$ gaussiennes standards.

$$\begin{aligned} \sup_{f \in \mathcal{F}} R_{\neq}(\hat{\psi}) &\geq E_{\Pi}[R_{\neq}(\hat{\psi})] \\ &\geq 2 \left[1 - \left\| \frac{1}{2} (\mathbf{P}_{0,1}^{\Pi} + \mathbf{P}_{1,0}^{\Pi}) - \mathbf{P}^{(0)} \right\|_{TV} - \left\| \frac{1}{2} (\mathbf{P}_{0,0}^{\Pi} + \mathbf{P}_{1,1}^{\Pi}) - \mathbf{P}^{(0)} \right\|_{TV} \right] \end{aligned}$$

$\|\mathbf{P}_{i,j}^{\Pi} - \mathbf{P}^{(0)}\|_{TV}$ est relié au risque du test

$$H_0 : (X_1, \dots, X_n, X, \tilde{X}) \sim \mathbf{P}^{(0)} \quad \text{contre} \quad H_1 : (X_1, \dots, X_n, X, \tilde{X}) \sim \mathbf{P}_{i,j}^{\Pi}$$

Données :

- Classe \mathcal{F} de mélange.
Ex1 : Σ fixe, μ_0 et μ_1 arbitraires. Ex2 : Σ fixe, $\mu_1 - \mu_0$ s -parcimonieux.
- une distance $d(\mu_0, \mu_1)$ entre les deux composantes.

Résultats asymptotique $(p, n) \rightarrow \infty$.

Données :

- Classe \mathcal{F} de mélange.
Ex1 : Σ fixe, μ_0 et μ_1 arbitraires. Ex2 : Σ fixe, $\mu_1 - \mu_0$ s -parcimonieux.
- une distance $d(\mu_0, \mu_1)$ entre les deux composantes.

Résultats asymptotique $(p, n) \rightarrow \infty$.

Risque de **détection** de mélange :

$$\gamma(T, r) := \sup_{f \in \mathcal{F}, \mu_0 = \mu_1} \mathbb{E}_f [T = 1] + \sup_{f, d(\mu_0, \mu_1) > r_n} \mathbb{E}_f [T = 0]$$

Frontière de détection "molle" r_n^* :

- si $r_n \ll r_n^*$ alors $\inf_{T_n} \gamma(T_n, r_n) \rightarrow 1$.
- si $r_n \gg r_n^*$ il existe une suite de tests T_n , $\gamma(T_n, r_n) \rightarrow 0$.

Données :

- Classe \mathcal{F} de mélange.
Ex1 : Σ fixe, μ_0 et μ_1 arbitraires. Ex2 : Σ fixe, $\mu_1 - \mu_0$ s -parcimonieux.
- une distance $d(\mu_0, \mu_1)$ entre les deux composantes.

Résultats asymptotique $(p, n) \rightarrow \infty$.

Risque de **détection** de mélange :

$$\gamma(T, r) := \sup_{f \in \mathcal{F}, \mu_0 = \mu_1} \mathbb{E}_f [T = 1] + \sup_{f, d(\mu_0, \mu_1) > r_n} \mathbb{E}_f [T = 0]$$

Frontière de détection "molle" r_n^* :

- si $r_n \ll r_n^*$ alors $\inf_{T_n} \gamma(T_n, r_n) \rightarrow 1$.
- si $r_n \gg r_n^*$ il existe une suite de tests T_n , $\gamma(T_n, r_n) \rightarrow 0$.

Définition correspondantes de frontière de **classification non supervisé, classification supervisé** :

$$\text{Si } r_n \ll r_n^* \text{ alors } \inf_{\hat{\psi}_n} \sup_{f, d(\mu_0, \mu_1) > r_n} R_{\neq}(\hat{\psi}_n) \rightarrow 2$$

$$\text{si } r_n \gg r_n^* \text{ alors il existe } \hat{\psi} \text{ tel que } \sup_{f, d(\mu_0, \mu_1) > r_n} R_{\neq}(\hat{\psi}_n) \rightarrow 0$$

Classification supervisé : [Ingster, Pouet, Tsybakov \(2009\)](#), [Donoho et Jin \(2009\)](#)

Classification non supervisé : [Azizyan, Singh et Wasserman \(2013\)](#), [Arias-Castro et V. \(2014\)](#)

Classification supervisé : Ingster, Pouet, Tsybakov (2009), Donoho et Jin (2009)

Classification non supervisé : Azizyan, Singh et Wasserman (2013), Arias-Castro et V. (2014)

Frontières dans le cas non parcimonieux (en fonction de $\|\Delta\mu\|^2$).

	$p/n \rightarrow 0$	$p/n \rightarrow \infty$
Test supervisé	$\sqrt{p/n}$	$\sqrt{p/n}$
Test de mélange	$\sqrt{p/n}$	$\sqrt{p/n}$
Classif. supervisée	$\rightarrow \infty$	$\sqrt{p/n}$
Classif. non supervisée	$\rightarrow \infty$	$\sqrt{p/n}$

Remarques : En petite dimension, le risque de classification est essentiellement dû au risque du classifieur de Bayes.

En grande dimension, à la frontière on a $\langle \frac{\widehat{\Delta\mu}}{\|\widehat{\Delta\mu}\|}, \frac{\Delta\mu}{\|\Delta\mu\|} \rangle \rightarrow 0$ mais

$\langle \frac{\widehat{\Delta\mu}}{\|\widehat{\Delta\mu}\|}, \Delta\mu \rangle \rightarrow \infty$

Proposition

Tous les tests sont asymptotiquement impuissants si

$$\|\Delta\mu\|^2 \ll \sqrt{p/n} .$$

Covariance du vecteur X :

$$\text{Cov}(X) = \nu(1 - \nu)\Delta\mu\Delta\mu^\top + \mathbf{I} .$$

$$\hat{\Sigma} = \sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})^\top$$

Proposition

La plus grande valeur propre est asymptotiquement puissante si

$$\nu(1 - \nu)\|\Delta\mu\|^2 \geq C\sqrt{p/n} .$$

$\Delta\mu$ est **s -parcimonieux** : s composantes au plus de $\Delta\mu$ sont non nulles.

Ingster, Pouet, Tsybakov (2009), Donoho et Jin (2009), Azizyan, Singh et Wasserman (2013), Arias-Castro et V. (2014)

Frontières dans le cas parcimonieux (en fonction de $\|\Delta\mu\|^2$).

	$\frac{s \log(p/s)}{n} \rightarrow 0$	$\frac{s \log(p/s)}{n} \rightarrow \infty$
Test supervisé	$\frac{s \log(p/s)}{n} \wedge \frac{\sqrt{p}}{n}$	$\frac{s \log(p/s)}{n} \wedge \frac{\sqrt{p}}{n}$
Test de mélange	$\sqrt{\frac{s \log(p/s)}{n}}$	$\frac{s \log(p/s)}{n} \wedge \sqrt{\frac{p}{n}}$
Classif. supervisée	$\rightarrow \infty$	$\frac{s \log(p/s)}{n} \wedge \sqrt{\frac{p}{n}}$
Classif. non supervisée	$\rightarrow \infty$	$\frac{s \log(p/s)}{n} \wedge \sqrt{\frac{p}{n}}$

Proposition

Supposons que $p/s \rightarrow \infty$. Alors aucun test est asymptotiquement puissant si

$$\|\Delta\mu\|^2 \ll \sqrt{p/n} .$$

et

$$\limsup \frac{\|\Delta\mu\|^2}{\sqrt{\frac{s \log(p/s)}{n}} \vee \frac{s \log(p/s)}{n}} < 1 .$$

$$\text{Cov}(X) = \nu(1 - \nu)\Delta\mu\Delta\mu^\top + \mathbf{I} .$$

Statistique de la plus grande valeur propre sparse :

$$\hat{\lambda}_s^{\max} := \max_{\|u\|=1, \|u\|_0 \leq s} u^\top \hat{\Sigma} u$$

Proposition

Supposons que $p/s \rightarrow \infty$.

- Détection. La plus grande valeur propre parcimonieuse $\hat{\lambda}_s^{\max}$ est asymptotiquement puissante si

$$\limsup \nu(1 - \nu) \frac{\|\Delta\mu\|^2}{\sqrt{\frac{s \log(p/s)}{n}} \vee \frac{s \log(p/s)}{n}} > C .$$

- Sélection de variable. Soit \hat{u} le vecteur associé à $\hat{\lambda}_s^{\max}$. Si

$$\|\Delta\mu\|^2 \gg \sqrt{\frac{s \log(p/s)}{n}} \vee \frac{s \log(p/s)}{n} ,$$

et si le dynamique range de $\Delta\mu$ est borné alors le support de \hat{u} est consistant pour le support de $\Delta\mu$.

Estimation de vecteur propre en ACP parcimonieuse : [Cai et al \(2013\)](#).

Toutes les méthodes précédentes ont des complexités polynomiales

... sauf $\hat{\lambda}_s^{\max} := \max_{\|u\|=1, \|u\|_0 \leq s} u^\top \hat{\Sigma} u$

Solution naive calculer $\hat{\lambda}_1^{\max} := \max_{\|u\|=1, \|u\|_0 \leq 1} u^\top \hat{\Sigma} u$

Autres solution (SDP) : D'aspremont et al. (2007) Berthet et Rigollet (2013)

Toutes les méthodes précédentes ont des complexités polynomiales

... sauf $\hat{\lambda}_s^{\max} := \max_{\|u\|=1, \|u\|_0 \leq s} u^\top \hat{\Sigma} u$

Solution naive calculer $\hat{\lambda}_1^{\max} := \max_{\|u\|=1, \|u\|_0 \leq 1} u^\top \hat{\Sigma} u$

Autres solution (SDP) : [D'aspremont et al. \(2007\)](#) [Berthet et Rigollet \(2013\)](#)

Condition suffisante en temps polynomial dans le cas parcimonieux.

	$\frac{s \log(p/s)}{n} \rightarrow 0$	$\frac{s \log(p/s)}{n} \rightarrow \infty$ (et $\log(p/s) = o(n)$)
Test supervisé	$\frac{s \log(p/s)}{n} \wedge \frac{\sqrt{p}}{n}$	$\frac{s \log(p/s)}{n} \wedge \frac{\sqrt{p}}{n}$
Test de mélange	$\sqrt{\frac{s^2 \log(p)}{n}} \wedge \sqrt{\frac{p}{n}}$	$\sqrt{\frac{s^2 \log(p)}{n}} \wedge \sqrt{\frac{p}{n}}$
Classif. supervisée	$\rightarrow \infty$	$\frac{s \log(p/s)}{n} \wedge \sqrt{\frac{p}{n}}$
Classif. non supervisée	$\rightarrow \infty$	$\sqrt{\frac{s^2 \log(p)}{n}} \wedge \sqrt{\frac{p}{n}}$

Toutes les méthodes précédentes ont des complexités polynomiales

... sauf $\hat{\lambda}_s^{\max} := \max_{\|u\|=1, \|u\|_0 \leq s} u^\top \hat{\Sigma} u$

Solution naive calculer $\hat{\lambda}_1^{\max} := \max_{\|u\|=1, \|u\|_0 \leq 1} u^\top \hat{\Sigma} u$

Autres solution (SDP) : D'aspremont et al. (2007) Berthet et Rigollet (2013)

Condition suffisante en temps polynomial dans le cas parcimonieux.

	$\frac{s \log(p/s)}{n} \rightarrow 0$	$\frac{s \log(p/s)}{n} \rightarrow \infty$ (et $\log(p/s) = o(n)$)
Test supervisé	$\frac{s \log(p/s)}{n} \wedge \frac{\sqrt{p}}{n}$	$\frac{s \log(p/s)}{n} \wedge \frac{\sqrt{p}}{n}$
Test de mélange	$\sqrt{\frac{s^2 \log(p)}{n}} \wedge \sqrt{\frac{p}{n}}$	$\sqrt{\frac{s^2 \log(p)}{n}} \wedge \sqrt{\frac{p}{n}}$
Classif. supervisée	$\rightarrow \infty$	$\frac{s \log(p/s)}{n} \wedge \sqrt{\frac{p}{n}}$
Classif. non supervisée	$\rightarrow \infty$	$\sqrt{\frac{s^2 \log(p)}{n}} \wedge \sqrt{\frac{p}{n}}$

Le terme s^2 est vraisemblablement intrinsèque...

Détection en ACP parcimonieuse : X échantillon de covariance $\Sigma = \mathbf{I} + \lambda vv^\top$ et v est s -parcimonieux.

$$H_0 : \lambda = 0 \text{ contre } H_1 : \lambda > \lambda_* .$$

Théorème (Berthet/Rigollet (2013))

Si le problème de la clique plantée n'est pas résolvable en temps polynomial, alors pour tout $1 < \delta < 2$ aucun test calculable en temps polynomial n'est asymptotiquement puissant si

$$\lambda_* \lesssim \sqrt{\frac{s^\delta \log(p)}{n}}$$

Dans la suite, Σ est inconnu (mais inversible). [Shao et al. \(2011\)](#) (Classif supervisé)

Frontières (distance de Mahalanobis $\Delta\mu^\top \Sigma^{-1} \Delta\mu$).

	$p = o(n)$	$p \gg n$
Test supervisé	$\left(\frac{p}{n}\right)^{1/2}$	$e^{O(p/n)}$
Test de mélange	$\left(\frac{p}{n}\right)^{1/4}$	$e^{O(p/n)}$
Classif. supervisée	$\rightarrow \infty$	$e^{O(p/n)}$
Classif. non supervisée	$\rightarrow \infty$	$e^{O(p/n)}$

Frontières sous s -parcimonie (en fonction de $\frac{\|\Delta\mu\|^4}{\Delta\mu^\top \Sigma \Delta\mu}$).

	$s \log(p/s) = o(n)$	$s \log(p/s) \gg n$
Test supervisé	$\left(\frac{s \log(p/s)}{n}\right)^{1/2}$	$e^{O(s \log(p/s)/n)}$
Test de mélange	$\left(\frac{s \log(p/s)}{n}\right)^{1/4}$	$e^{O(s \log(p/s)/n)}$
Classif. supervisée	$\rightarrow \infty$	$e^{O(s \log(p/s)/n)}$
Classif. non supervisée	$\rightarrow \infty$	$e^{O(s \log(p/s)/n)}$

Proposition

Supposons que $\nu = 1/2$.

- Cas non parcimonieux. Tous les tests sont asymptotiquement impuissants si

$$\frac{\|\Delta\mu\|^4}{\Delta\mu^\top \Sigma \Delta\mu} \ll (p/n)^{1/4} .$$

Si $p \gg n$, alors tous les tests sont asymptotiquement impuissants si

$$\limsup \frac{\|\Delta\mu\|^4}{\Delta\mu^\top \Sigma \Delta\mu} e^{-Cp/n} < 1 .$$

- Cas parcimonieux ($p/s \rightarrow \infty$). Tous les tests sont asymp. impuissants si

$$\limsup \frac{\|\Delta\mu\|^4}{\Delta\mu^\top \Sigma \Delta\mu} \left(\frac{s \log(p/s)}{n} \right)^{-1/4} \leq C_1 .$$

Si $\liminf \frac{s}{n} \log(p/s) \geq C_2$, alors tous les tests sont asymptotiquement impuissants lorsque

$$\limsup \frac{\|\Delta\mu\|^4}{\Delta\mu^\top \Sigma \Delta\mu} e^{-C_3 \frac{s \log(p/s)}{n}} \leq 1 .$$

Statistique de kurtosis généralisé :

$$\min_{\|u\|_0 \leq s} \frac{\sum_i [u^\top (X_i - \bar{X})]^4}{\left(\sum_i [u^\top (X_i - \bar{X})]^2\right)^2} .$$

Statistique de kurtosis généralisé :

$$\min_{\|u\|_0 \leq s} \frac{\sum_i [u^\top (X_i - \bar{X})]^4}{\left(\sum_i [u^\top (X_i - \bar{X})]^2\right)^2} .$$

Statistique de moment d'ordre 1 :

$$\max_{\|u\|_0 \leq s} \frac{\sum_i |u^\top (X_i - \bar{X})|}{\left(\sum_i [u^\top (X_i - \bar{X})]^2\right)^{1/2}} .$$

Statistique de kurtosis généralisé :

$$\min_{\|u\|_0 \leq s} \frac{\sum_i [u^\top (X_i - \bar{X})]^4}{\left(\sum_i [u^\top (X_i - \bar{X})]^2\right)^2}.$$

Statistique de moment d'ordre 1 :

$$\max_{\|u\|_0 \leq s} \frac{\sum_i |u^\top (X_i - \bar{X})|}{\left(\sum_i [u^\top (X_i - \bar{X})]^2\right)^{1/2}}.$$

Proposition

Supposons que $n \gg s \log(p/s)$. Le test d'ordre 1 est asymptotiquement puissant si $|\nu - 1/2| < \frac{1}{6}$ et si

$$\frac{\|\Delta\mu\|^4}{\Delta\mu^\top \Sigma \Delta\mu} \gg \left(s \frac{\log(p/s)}{n}\right)^{1/4}.$$

Proposition

Soit $\Delta\mu$ un vecteur 1-parsimonieux fixé. On considère le problème

$$H_0^\dagger : X_1, \dots, X_n \stackrel{\text{iid}}{\sim} \mathcal{N}(0, \mathbf{I}),$$

contre

$$H_1^\dagger : X_1, \dots, X_n \stackrel{\text{iid}}{\sim} \frac{1}{2}\mathcal{N}(-\frac{1}{2}\Delta\mu, \Sigma) + \frac{1}{2}\mathcal{N}(\frac{1}{2}\Delta\mu, \Sigma),$$

où $\Sigma - \mathbf{I}$ est de rang 1.

Si $p \gg n$, alors tous les tests sont asymptotiquement impuissants pour

$$\Delta\mu^\top \Sigma^{-1} \Delta\mu \ll \frac{e^{p/(2n)}}{np}.$$

Proposition

- Cas non parcimonieux. *Supposons que $p \rightarrow \infty$ et que $p = o(n)$. Tous les tests sont asymptotiquement impuissants si*

$$\frac{\|\Delta\mu\|^4}{\Delta\mu^\top \Sigma \Delta\mu} \ll (p/n)^{1/3} .$$

- Cas parcimonieux. *Supposons que $p/s \rightarrow \infty$ et que $n \gg s \log(p/s)$. Tous les tests sont asymptotiquement impuissants si*

$$\limsup \frac{\|\Delta\mu\|^4}{\Delta\mu^\top \Sigma \Delta\mu} \leq C \left(\frac{s \log(p/s)}{n} \right)^{1/3} .$$

Remarque. Frontière de détection plus grande que pour la covariance connue.

Statistique de skewness :

$$\max_{\|u\|_0 \leq s} \frac{\sum_i [u^\top (X_i - \bar{X})]^3}{\left(\sum_i [u^\top (X_i - \bar{X})]^2\right)^{3/2}}.$$

Statistique de skewness :

$$\max_{\|u\|_0 \leq s} \frac{\sum_i [u^\top (X_i - \bar{X})]^3}{\left(\sum_i [u^\top (X_i - \bar{X})]^2\right)^{3/2}}.$$

Statistique signée des moments d'ordre 2 :

$$\max_{\|u\|_0 \leq s} \frac{\sum_i [u^\top (X_i - \bar{X})]^2 \text{sign}(u^\top (X_i - \bar{X}))}{\sum_i [u^\top (X_i - \bar{X})]^2}.$$

Proposition

Supposons que $n \gg s \log(p/s)$. Le test est asymptotiquement puissant si

$$\liminf [\nu(1-\nu)|1-2\nu|]^{2/3} \frac{\|\Delta\mu\|^4}{\Delta\mu^\top \Sigma \Delta\mu} \left(\frac{s \log(p/s)}{n}\right)^{-1/3} \geq C.$$

- Pour des modèles isotropiques à 2 classes, peu de différences sensibles entre problèmes supervisés et non supervisés...
.... sauf sous des contraintes de complexité computationnel.
- Pour des modèles de mélange plus complexes (Σ arbitraires, grands k), aucune méthode **robuste** n'est connue.
- Apports d'un échantillon **semi-supervisé**?



Merci pour votre attention !