

FONDEMENTS DU ML

05/11/2024

Aujourd'hui:

- Maximum a posteriori (+ site la semaine prochaine?)
- TD 4 (Partie 1)

Dernier cours (12/11) : Présentation projet

→ TP régression linéaire

MAXIMUM A POSTERIORI

Contexte . Données ($X = \begin{bmatrix} x_1^T \\ \vdots \\ x_m^T \end{bmatrix} \in \mathbb{R}^{m \times m}$, $y = \begin{bmatrix} y_1 \\ \vdots \\ y_m \end{bmatrix} \in \mathbb{R}^m$)

• Hypothèse: $y = X\beta^* + \varepsilon$

$$\Leftrightarrow y_i = x_i^T \beta^* + \varepsilon_i \quad \forall i=1..m$$

$$\beta^* \in \mathbb{R}^m$$

$\varepsilon \in \mathbb{R}^m$ vecteur de bruit (aléatoire)

• Bruit gaussien: $\varepsilon \sim \mathcal{N}(0, \sigma^2 I_m)$ $\sigma > 0$

$$\Leftrightarrow \varepsilon_1, \dots, \varepsilon_m \text{ sont iid } \sim \mathcal{N}(0, \sigma^2)$$

$$\Leftrightarrow E[\varepsilon] = 0_{\mathbb{R}^m} \text{ et } E[\varepsilon \varepsilon^T] = \sigma^2 I_m$$

① Maximum de vraisemblance \rightarrow Maximum a posteriori:

\rightarrow L'estimateur du maximum de vraisemblance $\hat{\beta}^{MV} \in \mathbb{R}^m$ est défini comme une solution de

$$(P_{MV}) \max_{\beta \in \mathbb{R}^m} \mathcal{L}(y_1, \dots, y_m; \beta) \stackrel{\substack{\text{les nos} \\ \text{hypothèses}}}{=} \frac{1}{(2\pi\sigma^2)^{m/2}} \exp\left(-\sum_{i=1}^m \frac{(y_i - x_i^T \beta)^2}{2\sigma^2}\right)$$

Vraisemblance: probabilité que $y_1=y_1, \dots, y_m=y_m$ si $y_i \sim \mathcal{N}(x_i^T \beta, \sigma^2)$

\rightarrow L'ensemble des solutions de (P_{MV}) est identique à celui

de
$$\min_{\beta \in \mathbb{R}^m} \frac{1}{2\sigma^2} \|X\beta - y\|^2$$

ou encore

$$\min_{\beta \in \mathbb{R}^m} \frac{1}{2} \|X\beta - y\|^2$$

⇒ Problème aux moindres carrés linéaires, dont on sait caractériser les solutions.

↳ Plutôt que la vraisemblance, on aurait pu vouloir maximiser $\mathcal{L}(\beta; y_1, \dots, y_m)$

mais cette loi n'a pas d'expression directe simple (on ne peut pas calculer cette probabilité en général)

→ En revanche, comme

$$\mathcal{L}(\beta; y_1, \dots, y_m) \propto \underbrace{\mathcal{L}(y_1, \dots, y_m; \beta)}_{\text{vraisemblance}} \underbrace{\mathcal{L}(\beta)}_{\substack{\text{loi incconnue en} \\ \text{général, mais que l'on peut} \\ \text{définir via un a priori sur} \\ \text{notre modèle linéaire}}}$$

(formule de Bayes)

Définition Etant donnée une loi de probabilité $\mathcal{L}(\beta)$ sur \mathbb{R}^n , l'estimateur du maximum a posteriori pour (X, y) est défini comme solution du problème

$$\max_{\beta \in \mathbb{R}^n} \ln [\mathcal{L}(y_1, \dots, y_m; \beta) \mathcal{L}(\beta)]$$

On le note $\hat{\beta}^{\text{MAP}}$


NB: peut être défini sans le logarithme

$$\max_{\beta \in \mathbb{R}^n} \mathcal{L}(y_1, \dots, y_m; \beta) \mathcal{L}(\beta)$$


- Implication :
- Pour toute loi a priori sur β , on peut définir un maximum a posteriori
 - Selon la loi, on peut disposer ou non d'une formule explicite pour $\hat{\beta}^{\text{MAP}}$, ainsi que de garanties statistiques.
 - La loi a priori dépend souvent d'un paramètre qui permet de quantifier le poids de l'a priori par rapport à la vraisemblance

- Exemples d'a priori
- $\beta \sim N(0, (\frac{1}{\lambda})I_m) \quad \lambda > 0$
 - $\beta \sim \text{Laplace}(0, \frac{1}{\lambda}) \quad \lambda > 0$

$z \in \mathbb{R}, z \sim \text{Laplace}(\bar{z}, \frac{1}{\lambda}), P(z=t) \propto \exp\left(-\frac{|t-\bar{z}|}{\lambda}\right)$



- $\beta \sim \text{Dirac}(\beta_0) \quad P(\beta = \beta_0) = 1 \quad P(\beta \neq \beta_0) = 0$



...
 \Rightarrow le choix de l'a priori dépend du problème / de l'expertise métier
 \Rightarrow on peut toujours faire sans a priori (maximum de vraisemblance)

② Cas d'un a priori gaussien

On suppose un a priori gaussien centré en 0 sur β , c'est à dire que
on considère $\beta \sim N(0, (\frac{1}{\lambda}) I_m)$ $\lambda > 0$

\Rightarrow Revient à dire que l'on cherche une solution proche du vecteur nul

\Rightarrow La valeur de λ détermine/quantifie à quel point on souhaite considérer des valeurs éloignées de 0

$\lambda \rightarrow 0$: A priori \rightarrow Pas d'a priori (variance infinie)

$\lambda \rightarrow \infty$: A priori \rightarrow Dirac(0)

Sous les hypothèses de départ ($y = X\beta + \varepsilon$, $\varepsilon \sim N(0, \sigma^2 I_m)$) et avec cet a priori, on a:

$$\mathcal{L}(y_1, \dots, y_m; \beta) = \frac{1}{(2\pi\sigma^2)^{m/2}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^m (x_i^T \beta - y_i)^2\right)$$

et

$$\mathcal{L}(\beta) = \frac{1}{(2\pi/\lambda)^{m/2}} \exp\left(-\frac{1}{2/\lambda} \sum_{j=1}^m \beta_j^2\right)$$

$\forall j \quad \beta_j \sim N(0, 1/\lambda)$

Par conséquent,

$$\ln[\mathcal{L}(y_1, \dots, y_m; \beta) \mathcal{L}(\beta)] = \ln\left(\frac{1}{(2\pi\sigma^2)^{m/2}}\right) - \frac{1}{2\sigma^2} \sum_{i=1}^m (x_i^T \beta - y_i)^2 + \ln\left(\frac{1}{(2\pi/\lambda)^{m/2}}\right) - \frac{1}{2/\lambda} \sum_{j=1}^m \beta_j^2$$

Le problème d'estimation du maximum a posteriori est

$$\max_{\beta \in \mathbb{R}^m} \left\{ \underbrace{\ln\left(\frac{1}{(2\pi\sigma^2)^{m/2}}\right) + \ln\left(\frac{1}{(2\pi/\lambda)^{m/2}}\right)}_{\text{constantes (ne dépendent pas de } \beta)} - \frac{1}{2\sigma^2} \sum_{i=1}^m (x_i^T \beta - y_i)^2 - \frac{1}{2/\lambda} \sum_{j=1}^m \beta_j^2 \right\}$$

qui a le même ensemble de solutions que

$$\max_{\beta \in \mathbb{R}^m} -\frac{1}{2\sigma^2} \sum_{i=1}^m (x_i^T \beta - y_i)^2 - \frac{1}{2/\lambda} \sum_{j=1}^m \beta_j^2 = -\frac{1}{2\sigma^2} \|X\beta - y\|^2 - \frac{\lambda}{2} \|\beta\|^2$$

Théorème Sous les hypothèses ci-dessus

- le problème d'estimation du maximum a posteriori a le même ensemble de solutions que

$$\min_{\beta \in \mathbb{R}^m} \frac{1}{2\sigma^2} \|X\beta - y\|^2 + \frac{\lambda}{2} \|\beta\|^2$$

qui est un problème aux moindres carrés linéaires.

- Pour $\lambda > 0$, les deux problèmes possèdent une unique solution

donnée par

$$\hat{\beta}^{\text{MAP}} = (X^T X + \lambda \sigma^2 I_m)^{-1} X^T y$$

Principe de preuve

$$\rightarrow \max_{\beta \in \mathbb{R}^m} -f(\beta) \Leftrightarrow \min_{\beta \in \mathbb{R}^m} f(\beta)$$

$$\begin{aligned} \rightarrow \frac{1}{2\sigma^2} \|X\beta - y\|^2 + \frac{\lambda}{2} \|\beta\|^2 &= \frac{1}{2\sigma^2} \left(\|X\beta - y\|^2 + \lambda \sigma^2 \|\beta\|^2 \right) \\ &= \frac{1}{2\sigma^2} \left(\beta^T X^T X \beta - 2 \beta^T X^T y + y^T y + \lambda \sigma^2 \beta^T \beta \right) \end{aligned}$$

$$= \frac{1}{2\sigma^2} \left(\beta^T (X^T X + \lambda \sigma^2 I) \beta - 2\beta^T X^T y + y^T y \right)$$

$$\forall X \in \mathbb{R}^{m \times n}, \quad X^T X + \lambda \sigma^2 I \succ 0$$

$$\text{car } (X^T X + \lambda \sigma^2 I)^T = (X^T X)^T + \lambda \sigma^2 I^T = X^T X + \lambda \sigma^2 I$$

$$\text{et } \forall v \in \mathbb{R}^m, \quad v^T (X^T X + \lambda \sigma^2 I) v = \underbrace{\|Xv\|^2}_{\geq 0} + \lambda \sigma^2 \underbrace{\|v\|^2}_{> 0 \text{ si } v \neq 0}$$

$$> 0 \text{ si } v \neq 0$$

Par conséquent, il existe $M > 0$ telle que $M^2 = M^T M = X^T X + \lambda \sigma^2 I$
 En utilisant cette matrice, on écrit

$$\beta^T (X^T X + \lambda \sigma^2 I) \beta - 2\beta^T X^T y + y^T y$$

$$= \beta^T M^T M \beta - 2\beta^T \underbrace{M^T M^{-1}}_I X^T y + y^T y$$

$$= \|M\beta - M^{-1} X^T y\|^2 - y^T X M^{-1} M^{-T} X^T y + y^T y$$

$$a^2 - 2ab = (a-b)^2 - b^2$$

$$\tilde{a}^T \tilde{a} - 2\tilde{a}^T \tilde{b} = \|\tilde{a} - \tilde{b}\|^2 - \tilde{b}^T \tilde{b}$$

Le problème aux moindres carrés s'écrit

$$\min_{\beta \in \mathbb{R}^m} \frac{1}{2\sigma^2} \left(\|M\beta - M^{-1} X^T y\|^2 - \underbrace{y^T X M^{-1} M^{-T} X^T y + y^T y}_{\substack{\uparrow \\ \text{constante indépendante} \\ \text{de } \beta}} \right)$$

↑ constante > 0

qui a le même ensemble de solutions que

$$\min_{\beta \in \mathbb{R}^m} \frac{1}{2} \|M\beta - M^{-1} X^T y\|^2$$

$\rightarrow M > 0 \Rightarrow M$ est de rang plein et carré
 \Rightarrow le problème a une unique solution donnée

par $\hat{\beta} = M^{-1} M^{-T} X^T y$

$$= (M^{-2})^T X^T y$$

$$= (M^2)^{-1} X^T y = (X^T X + \lambda \sigma^2 I)^{-1} X^T y$$

Remarques:

• Lorsque $\varepsilon \sim N(0, \sigma^2 I_m)$, on définit l'a priori gaussien en posant $\beta \sim N(0, \frac{\sigma^2}{\lambda} I_n)$, ce qui permet d'éliminer σ^2 dans le résultat final.

• Le problème aux moindres carrés $\min_{\beta \in \mathbb{R}^n} \frac{1}{2\sigma^2} \|X\beta - y\|^2 + \frac{\lambda}{2} \|\beta\|^2$ s'appelle un problème avec

notions équivalentes $\left\{ \begin{array}{l} - \text{régularisation } \ell_2 \\ - \text{régularisation de Tycheroff} \\ - \text{régularisation écrêtée ("ridge")} \end{array} \right.$

• On dit que la régularisation ℓ_2 réduit la variance de la solution par rapport aux données

Ex) $X = \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix}$ $y = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$ $\hat{\beta}^{MV} = \hat{\beta}^{OLS} = X^T y = \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} 1 \\ 1 \end{bmatrix} = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$
 $\|\hat{\beta}^{MV}\| = 1$

On perturbe $X \rightarrow \tilde{X} = \begin{bmatrix} 1 & 0 \\ 0 & \eta \end{bmatrix}$ $0 < \eta \ll 1$

$$(\tilde{X}, y) \rightarrow \tilde{X}^T y = \begin{bmatrix} 1 & 0 \\ 0 & \frac{1}{\gamma} \end{bmatrix} \begin{bmatrix} 1 \\ 1 \end{bmatrix} = \begin{bmatrix} 1 \\ \frac{1}{\gamma} \end{bmatrix}$$

$$\|(\tilde{X}^T y)\| \xrightarrow{\gamma \rightarrow 0} \infty$$

Avec régularisation l_2 / a priori gaussien

$$\hat{\beta}^{\text{MAP}} = (\tilde{X}^T \tilde{X} + \lambda I) \tilde{X}^T y$$

$$= \begin{bmatrix} 1+\lambda & 0 \\ 0 & \gamma^2+\lambda \end{bmatrix}^{-1} \begin{bmatrix} 1 \\ \gamma \end{bmatrix}$$

$$= \begin{bmatrix} \frac{1}{1+\lambda} \\ \frac{\gamma}{\gamma^2+\lambda} \end{bmatrix}$$

$$\|\hat{\beta}^{\text{MAP}}\| \xrightarrow{\gamma \rightarrow 0} \frac{1}{1+\lambda}$$

$$(X^T X + \lambda I)^{-1} X^T y = \begin{bmatrix} \frac{1}{1+\lambda} \\ 0 \end{bmatrix}$$

Quand $\lambda \rightarrow \infty$, $\hat{\beta}^{\text{MAP}} \rightarrow \begin{bmatrix} 0 \\ 0 \end{bmatrix}$

Propriétés statistiques pour $\hat{\beta}^{\text{MAP}}$ dans le cas d'un a priori gaussien

Sous les hypothèses $y = X\beta^* + \varepsilon$, $\varepsilon \sim N(0, \sigma^2 I_m)$ et l'a priori

$$\beta \sim N(0, (\frac{1}{\lambda}) I_m), \text{ on peut } \hat{\beta}^{\text{MAP}} = (X^T X + \lambda \sigma^2 I)^{-1} X^T y$$

Alors 1) $E[\hat{\beta}^{\text{MAP}}] = (X^T X + \lambda \sigma^2 I)^{-1} X^T X \beta^* \neq \beta^*$ en général

2) La matrice de covariance de $\hat{\beta}^{\text{MAP}}$ vaut

$$\Sigma_{\hat{\beta}^{\text{MAP}}} = (X^T X + \lambda \sigma^2 I)^{-1}, \text{ et } \|\Sigma_{\hat{\beta}^{\text{MAP}}}\| \leq \|\Sigma_{\hat{\beta}^{\text{ML}}}\|$$

avec $\hat{\beta}^{\text{ML}} = X^T y$ l'estimateur du maximum de vraisemblance.

→ On dit que l'estimateur $\hat{\beta}^{\text{MAP}}$ réduit la variance au prix d'un biais plus élevé

Bilan

→ Principe du maximum a posteriori et problème d'estimation/d'optimisation associé

→ le cas de l'a priori gaussien: équivalence avec un problème aux moindres carrés, solution (unique!) et propriétés statistiques