

Regression avancée
Chapitre 2 : la famille exponentielle et le maximum de
vraisemblance

Agathe Guilloux
Professeure au LaMME - Université d'Évry - Paris Saclay

Quelques exemples

Exemples de lois continues

- ▶ Loi normale (à densité par rapport à la mesure de Lebesgue sur \mathbb{R})
 $\mathcal{N}(\mu, 1)$ avec $\mu \in \mathbb{R}$

$$\frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}(y - \mu)^2\right) \text{ sur } \mathbb{R}$$

- ▶ Loi exponentielle (à densité par rapport à la mesure de Lebesgue sur \mathbb{R}_+)
 $\mathcal{E}(\lambda)$ avec $\lambda > 0$

$$\lambda \exp(-\lambda y) \text{ sur } \mathbb{R}_+$$

- ▶ Loi log-normale (à densité par rapport à la mesure de Lebesgue sur \mathbb{R}_+)
 $\log \mathcal{N}(\mu, 1)$ avec $\mu \in \mathbb{R}$
Rappel $Y \sim \log \mathcal{N}(\mu, 1) \Leftrightarrow \log(Y) \sim \mathcal{N}(\mu, 1)$

$$\frac{1}{\sqrt{2\pi y}} \exp\left(-\frac{1}{2}(\log(y) - \mu)^2\right) \text{ sur } \mathbb{R}_+^*$$

Exemples de lois discrètes

- ▶ Loi de Bernoulli (à densité par rapport à la mesure de comptage sur $\{0, 1\}$) $\beta(p)$ avec $p \in]0, 1[$

$$p^y(1-p)^{1-y} \text{ pour } y \in \{0, 1\}$$

- ▶ Loi de Poisson (à densité par rapport à la mesure de comptage sur \mathbb{N}) $\mathcal{P}(\lambda)$ avec $\lambda > 0$

$$\exp(-\lambda) \frac{\lambda^y}{y!} \text{ pour } y \in \mathbb{N}$$

Exemples de lois continues

- ▶ Loi normale $\mathcal{N}(\mu, 1)$

$$\frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}(y - \mu)^2\right) = \exp\left(y\mu - \frac{1}{2}\mu^2 - \frac{1}{2}y^2 - \log(y) - \log(\sqrt{2\pi})\right)$$

- ▶ Loi exponentielle $\mathcal{E}(\lambda)$

$$\lambda \exp(-\lambda y) = \exp(-\lambda y + \log(\lambda))$$

- ▶ Loi log-normale $\log \mathcal{N}(\mu, 1)$

$$\begin{aligned} & \frac{1}{\sqrt{2\pi y}} \exp\left(-\frac{1}{2}(\log(y) - \mu)^2\right) \\ &= \exp\left(\log(y)\mu - \frac{1}{2}\mu^2 - \frac{1}{2}(\log y)^2 - \log(y) - \log(\sqrt{2\pi})\right) \end{aligned}$$

Exemples de lois discrètes

- ▶ Loi de Bernoulli $\beta(p)$

$$p^y(1-p)^{1-y} = \exp\left(y \log\left(\frac{p}{1-p}\right) + \log(1-p)\right)$$

- ▶ Loi de Poisson $\mathcal{P}(\lambda)$

$$\exp(-\lambda) \frac{\lambda^y}{y!} = \exp\left(y \log(\lambda) - \lambda - \log(y!)\right)$$

La famille exponentielle naturelle : définitions

Qu'ont en commun ces lois

On peut récrire leurs densités sous la forme

$$\exp(\eta T(y) - A(\eta) - c(y))$$

ou presque

Proposition

Soient \mathcal{Y} un espace mesurable, ν une mesure positive sur \mathcal{Y} , T une fonction mesurable sur \mathcal{Y} (supposée non ν -p.p. constante) et c une fonction mesurable. On définit $\mathcal{H} = \{ \eta \in \mathbb{R} : \int_{\mathcal{Y}} \exp(\eta T(y) - c(y)) d\nu(y) < \infty \}$ et l'on suppose que $\overset{\circ}{\mathcal{H}} \neq \emptyset$ alors

la fonction $\eta \mapsto \int_{\mathcal{Y}} \exp(\eta T(y) - c(y)) d\nu(y)$ est infiniment différentiable sur $\overset{\circ}{\mathcal{H}}$ et de dérivée k -ième

$$\int_{\mathcal{Y}} T^k(y) \exp(\eta T(y) - c(y)) d\nu(y).$$

Famille exponentielle naturelle

Famille exponentielle naturelle

On se donne une mesure positive ν sur \mathcal{Y} , une fonction T (non ν p.p. constante) telles que $\overset{\circ}{\mathcal{H}} \neq \emptyset$ alors on définit la famille exponentielle naturelle comme la famille des lois de densités g_η pour $\eta \in \overset{\circ}{\mathcal{H}}$ par rapport à ν de la forme

$$g_\eta(y) = \exp(\eta T(y) - A(\eta) - c(y)).$$

Propriété

On a forcément

$$A(\eta) = \log \left(\int_{\mathcal{Y}} \exp(\eta T(y) - c(y)) d\nu(y) \right).$$

Exemples

- ▶ Loi normale $\mathcal{N}(\mu, 1)$

$$\frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}(y - \mu)^2\right) = \exp\left(y\mu - \frac{1}{2}\mu^2 - \frac{1}{2}y^2 - \log(y) - \log(\sqrt{2\pi})\right)$$

- ▶ Loi log-normale $\log \mathcal{N}(\mu, 1)$

$$\begin{aligned} & \frac{1}{\sqrt{2\pi y}} \exp\left(-\frac{1}{2}(\log(y) - \mu)^2\right) \\ &= \exp\left(\log(y)\mu - \frac{1}{2}\mu^2 - \frac{1}{2}(\log y)^2 - \log(y) - \log(\sqrt{2\pi})\right) \end{aligned}$$

Premières propriétés

Dans une famille exponentielle naturelle (sur \mathcal{Y} , pour une mesure positive ν et une fonction T), on a

$$\mathbb{E}_\eta(T(Y)) = A'(\eta)$$

$$\mathbb{V}_\eta(T(Y)) = A''(\eta)$$

pour tout $\eta \in \overset{\circ}{\mathcal{H}}$.

Exemples

- ▶ Loi normale $\mathcal{N}(\mu, 1)$

$$\frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}(y - \mu)^2\right) = \exp\left(y\mu - \frac{1}{2}\mu^2 - \frac{1}{2}y^2 - \log(y) - \log(\sqrt{2\pi})\right)$$

On a $T = \text{id}$, $\eta = \mu$, $A(\eta) = \mu^2/2$ et

$$A'(\eta) = \eta$$

$$A''(\eta) = 1.$$

- ▶ Loi log-normale $\log \mathcal{N}(\mu, 1)$

$$\begin{aligned} & \frac{1}{\sqrt{2\pi y}} \exp\left(-\frac{1}{2}(\log(y) - \mu)^2\right) \\ &= \exp\left(\log(y)\mu - \frac{1}{2}\mu^2 - \frac{1}{2}(\log y)^2 - \log(y) - \log(\sqrt{2\pi})\right) \end{aligned}$$

On a $T = \log$, $\eta = \mu$, $A(\eta) = \mu^2/2$ et

$$A'(\eta) = \eta$$

$$A''(\eta) = 1.$$

Estimation au maximum de vraisemblance

Echantillon et vraisemblance

On a un échantillon de v.a. i.i.d. Y_1, \dots, Y_n de densité g_{η^*} (dans une famille exponentielle naturelle) avec $\eta^* \in \overset{\circ}{\mathcal{H}}$ et inconnu.

Log-vraisemblance et score

La log-vraisemblance (divisée par $1/n$) de l'échantillon en tout point $\eta \in \overset{\circ}{\mathcal{H}}$ est donnée par

$$L(Y_1, \dots, Y_n; \eta) = \frac{1}{n} \sum_{i=1}^n \log \left(g_{\eta}(Y_i) \right) = \frac{1}{n} \sum_{i=1}^n T(Y_i) - A(\eta) - \frac{1}{n} \sum_{i=1}^n c(Y_i).$$

Propriété de la log-vraisemblance

La log-vraisemblance (divisée par $1/n$) $\eta \in \overset{\circ}{\mathcal{H}} \mapsto L(Y_1, \dots, Y_n; \eta)$ est une fonction strictement concave sur $\overset{\circ}{\mathcal{H}}$. Donc s'il existe $\hat{\eta} \in \overset{\circ}{\mathcal{H}}$ tel que

$$L'(Y_1, \dots, Y_n; \eta) = 0 \Leftrightarrow \frac{1}{n} \sum_{i=1}^n T(Y_i) = A'(\hat{\eta}),$$

c'est l'unique estimateur au maximum de vraisemblance de η^* .

Définition

Famille exponentielle générale

On se donne une mesure positive ν sur \mathcal{Y} , une fonction T (non ν p.p. constante) et une fonction $Q \mathcal{C}^1$ strictement monotone. On définit alors la famille de densités

$$f_{\theta}(y) = \exp(Q(\theta)T(y) - \alpha(\theta) - c(y)).$$

Remarque : on retrouve la famille exponentielle naturelle en posant

$$\eta = Q(\theta) \text{ et } A(\eta) = \alpha(Q^{-1}(\eta)).$$

Exemples

- ▶ Loi exponentielle $\mathcal{E}(\lambda)$

$$\lambda \exp(-\lambda y) = \exp(-\lambda y + \log(\lambda)).$$

On pose $T = \text{id}$, $Q(\lambda) = -\lambda$, et $\alpha(\lambda) = -\log(\lambda)$.

- ▶ Loi de Bernoulli $\beta(p)$

$$p^y(1-p)^{1-y} = \exp\left(y \log\left(\frac{p}{1-p}\right) + \log(1-p)\right).$$

On pose $T = \text{id}$, $Q(p) = p/(1-p)$, et $\alpha(p) = -\log(1-p)$.

- ▶ Loi de Poisson $\mathcal{P}(\lambda)$

$$\exp(-\lambda) \frac{\lambda^y}{y!} = \exp\left(y \log(\lambda) - \lambda - \log(y!)\right)$$

On pose $T = \text{id}$, $Q(\lambda) = \log(\lambda)$, et $\alpha = \text{id}$.

Propriétés asymptotiques de l'EMV

Pour l'estimation de $A'(\eta^*)$, on choisit

$$\widehat{A'(\eta^*)} = A'(\hat{\eta}) = \frac{1}{n} \sum_{i=1}^n T(Y_i).$$

- ▶ la loi des grands nombres indique que $\widehat{A'(\eta^*)} \xrightarrow{P.S.} \mathbb{E}(T(Y_i)) = A'(\eta^*)$.
- ▶ la théorie central limite implique que

$$\frac{\sqrt{n} \frac{1}{n} \sum_{i=1}^n T(Y_i) - A'(\eta^*)}{\sqrt{A''(\eta^*)}} \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1)$$

- ▶ avec le lemme de Slutsky, on obtient

$$\frac{\sqrt{n} \frac{1}{n} \sum_{i=1}^n T(Y_i) - A'(\eta^*)}{\sqrt{A''(\hat{\eta})}} \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1).$$

Si on veut des résultats pour η^* , il faut utiliser le théorème d'application continue et la delta-méthode.

Outline

Quelques exemples

Exemples de lois continues

Exemples de lois discrètes

La famille exponentielle naturelle : définitions

Qu'ont en commun ces lois

Preliminaire d'analyse

Famille exponentielle naturelle

Premières propriétés

Estimation au maximum de vraisemblance

L'estimateur au maximum de vraisemblance

Famille exponentielle générale

Propriétés asymptotiques de l'EMV