

Modèles à variables latentes pour l'écologie

Examen du 24 mars 2025

Durée : 2 heures

Les notes de cours sur papier et une calculatrice sont autorisées,
à l'exclusion de tout autre appareil électronique (tablette & téléphone compris).

1 Estimation d'un nombre d'espèces

On souhaite estimer le nombre n total d'espèces de papillons présentes dans un site particulier. On organise pour cela une campagne de capture au cours de laquelle on observe m espèces. On note Y_j^+ le nombre d'individus capturés appartenant à l'espèce $j \in \{1, \dots, m\}$.

Pour estimer n , il faut de plus estimer le nombre n_0 d'espèces présentes dans le site, mais dont aucun individu n'a été capturé. On aura alors $n = m + n_0$. On se propose pour cela de définir un modèle pour le nombre d'individus capturés d'une espèce, en autorisant celui-ci à être nul.

Loi Poisson-Gamma. La loi Poisson-Gamma, notée $Y \sim \mathcal{PGam}(a, b)$ est construite de la façon suivante : on tire d'abord une variable Z selon une loi Gamma de paramètres a et b , puis on tire la variable Y selon une loi de Poisson de paramètre Z :

$$Z \sim \mathcal{Gam}(a, b), \quad Y \mid Z \sim \mathcal{P}(Z). \quad (1)$$

On rappelle que la densité de la loi Gamma est définie pour $z \in \mathbb{R}^+$ et vaut

$$\mathcal{Gam}(z; a, b) = \frac{b^a}{\Gamma(a)} z^{a-1} e^{-bz}.$$

On rappelle également que la fonction de probabilité de la loi de Poisson est $\mathcal{P}(y; \lambda) = e^{-\lambda} \lambda^y / y!$ pour $y \in \mathbb{N}$.

Probabilité de ne pas observer une espèce.

1. Comment interpréter la variable latente Z ?
2. Montrer que la loi marginale de y est donnée, pour $y \in \mathbb{N}$, par

$$p(y) = \mathbb{P}\{Y = y\} = \frac{\Gamma(a+y)}{\Gamma(a)y!} \frac{b^a}{(b+1)^{a+y}}.$$


3. En déduire que, selon la loi Poisson-Gamma (1), la probabilité de ne pas observer une espèce vaut $[b/(b+1)]^a$.

Modèle pour l'ensemble des espèces. On note maintenant Y_i ($1 \leq i \leq n$) le nombre (éventuellement nul) d'individus capturés pour chacune des n espèces présentes. On suppose que les Y_i sont iid et de loi $\mathcal{PGam}(a, b)$. On note p^+ la loi du nombre Y_j^+ d'individus capturés pour une espèce j ($1 \leq j \leq m$) dont on a observé au moins un individu.

4. Donner $p^+(y)$.
5. Proposer succinctement une méthode d'estimation des paramètres a et b à partir des effectifs Y_1^+, \dots, Y_m^+ observés.

Estimation du nombre d'espèces. La figure suivante donne la distribution des effectifs Y_j^+ de $m = 501$ espèces des papillons capturés dans une forêt de Malaisie [Fisher et al., 1943]. Pour 118 espèces, on a observé un seul individu, pour 74

espèces on en a observé deux et ainsi de suite.



On a estimé à partir de ces données les valeurs des paramètres a et b et on a obtenu

$$\hat{a} = 0.49, \quad \hat{b} = 0.11.$$

La courbe donne la distribution p^+ pour les paramètres (\hat{a}, \hat{b}) .

6. Donner une estimation de la probabilité $p(0)$ qu'une espèce présente ne soit pas observée.
7. En déduire un estimateur des moments et l'estimation correspondante \hat{n}_0 du nombre d'espèces présentes mais non-observées et une estimation \hat{n} du nombre total d'espèces présentes.

2 Approximation variationnelle pour la loi Poisson log-normale unidimensionnelle

Modèle. On considère le modèle Poisson log-normal univarié défini de la façon suivante :

$$Z \sim \mathcal{N}(0, \sigma^2), \quad Y \mid Z \sim \mathcal{P}(e^{\mu+Z})$$

dont le paramètre est $\theta = (\mu, \sigma^2)$.

On cherche une approximation de la loi conditionnelle $p_\theta(Z \mid Y)$ au sein de la classe des lois normales :

$$\mathcal{Q} = \{q = \mathcal{N}(m, s^2), m \in \mathbb{R}, s^2 \in \mathbb{R}^{*+}\}.$$

On rappelle que la divergence de Kullback-Leibler entre deux distributions f et g vaut

$$KL[f \parallel g] = \mathbb{E}_{X \sim f} \left(\log \frac{f(X)}{g(X)} \right).$$

Approximation variationnelle. On considère tout d'abord la divergence

$$D_1(q; p) = KL[q \parallel p(\cdot \mid Y)].$$

1. Montrer que, si U suit une loi normale $\mathcal{N}(\nu, \gamma^2)$, alors $\mathbb{E}(e^U) = \exp(\nu + \gamma^2/2)$.
2. Écrire, à une constante additive près, $D_1(q; p)$ en fonction des paramètres (m, s^2) de la loi q .
3. En déduire que les paramètres m_1 et s_1^2 de la loi q_1 qui minimisent $D_1(q; p)$ au sein de \mathcal{Q} satisfont

$$\begin{cases} m_1 &= \sigma^2 \left(Y - e^{\mu+m_1+s_1^2/2} \right), \\ 1/s_1^2 &= e^{\mu+m_1+s_1^2/2} + 1/\sigma^2. \end{cases} \quad (2)$$

4. Montrer que le système (2) admet un unique couple de solutions (m_1, s_1^2) .

Approximation par propagation de l'espérance. On considère maintenant la divergence

$$D_2(q; p) = KL[p(\cdot \mid Y) \parallel q].$$

5. Écrire, à une constante additive près, $D_2(q; p)$ en fonction des paramètres (m, s^2) de la loi q .
(On pourra exprimer les résultats sous la forme de moments conditionnels sous la loi p : $\mathbb{E}_p[f(Z) \mid Y]$.)
6. En déduire les paramètres optimaux m_2 et s_2^2 de la loi q_2 qui minimise $D_2(q; p)$ au sein de \mathcal{Q} .
(On pourra encore exprimer les résultats sous la forme $\mathbb{E}_p[f(Z) \mid Y]$.)

Références

R. A Fisher, A S. Corbet, and C. B Williams. The relation between the number of species and the number of individuals in a random sample of an animal population. *The Journal of Animal Ecology*, pages 42–58, 1943.