

TD/TP : Régression à processus logistique latent

On considère une série temporelle (Y_1, \dots, Y_n) régie par un processus latent (Z_1, \dots, Z_n) à deux états où Z_t représente l'état (binaire dans ce cas) à l'instant t ($t = 1, \dots, n$). $Z_t \in \{0, 1\}$. On dispose d'une série observée (y_1, \dots, y_n) . L'objectif est de prédire et de segmenter la série sur la base du modèle de régression à processus logistique latent défini par :

$$\begin{aligned} f(y_t; \boldsymbol{\theta}) &= \pi(t; \mathbf{w})f(y_t; \boldsymbol{\theta}_1) + (1 - \pi(t; \mathbf{w}))f(y_t; \boldsymbol{\theta}_0) \\ &= \pi(t; \mathbf{w})\mathcal{N}(\beta_{10} + \beta_{11}t, \sigma_1^2) + (1 - \pi(t; \mathbf{w}))\mathcal{N}(\beta_{00} + \beta_{01}t, \sigma_0^2) \end{aligned} \quad (1)$$

où $\pi(t; \mathbf{w})$ est le poids logistique de l'état 1 à l'instant t défini par

$$\pi(t; \mathbf{w}) = \mathbb{P}(Z_t = 1; \mathbf{w}) = \frac{\exp(w_0 + w_1 t)}{1 + \exp(w_0 + w_1 t)} \quad (2)$$

avec $\mathbb{P}(Y_t = 0; \boldsymbol{\theta}) = \frac{1}{1 + \exp(w_0 + w_1 t)}$.

Afin d'apprendre ce modèle en estimant les paramètres $\boldsymbol{\theta} = (\mathbf{w}, \boldsymbol{\beta}, \sigma_0^2, \sigma_1^2)$ à partir des données et faire la segmentation de la série, on utilise l'algorithme Espérance-Maximisation (EM).

On montre que pour ce modèle l'algorithme EM consiste à partir d'un modèle initial de paramètres $\boldsymbol{\theta}^{(0)}$ et alterner à chaque itération q entre les deux étapes E- et M- suivantes jusqu'à ce qu'il n'y ait plus d'augmentation significative au sens d'un seuil préfixé de la log-vraisemblance du modèle :

1. Étape E : Calculer les probabilités a posteriori :

$$\tau_{tk}^{(q)} = \mathbb{P}(Z_t = k | y_t, \boldsymbol{\theta}^{(q)}) = \frac{\pi_k(t; \mathbf{w}^{(q)}) \mathcal{N}(y_t; \beta_{k0} + \beta_{k1}t, \sigma_k^2)}{f(y_t; \boldsymbol{\theta}^{(q)})} \quad (3)$$

2. Étape M : Mettre à jour les paramètres du modèle $\boldsymbol{\theta}^{(t+1)}$:

pour $k \in \{0, 1\}$:

$$\beta_{k0}^{(q+1)} = \frac{\sum_{t=1}^n \tau_k(t; \boldsymbol{\theta}^{(q)}) (y_t - \beta_{k1}^{(q)} t)}{\sum_{t=1}^n \tau_k(t; \boldsymbol{\theta}^{(q)})} \quad (4)$$

$$\beta_{k1}^{(q+1)} = \frac{\sum_{t=1}^n \tau_k(t; \boldsymbol{\theta}^{(q)}) (y_t - \beta_{k0}^{(q+1)}) t}{\sum_{t=1}^n \tau_k(t; \boldsymbol{\theta}^{(q)}) t^2} \quad (5)$$

$$(6)$$

où de façon équivalente

$$\beta_k^{(q+1)} = \left[\sum_{t=1}^n \tau_k(t; \boldsymbol{\theta}^{(q)}) \mathbf{x}_t \mathbf{x}_t^T \right]^{-1} \sum_{t=1}^n \tau_k(t; \boldsymbol{\theta}^{(q)}) y_t \mathbf{x}_t \quad (7)$$

$$= (\mathbf{X}^T \mathbf{W}^{(q)} \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W}^{(q)} \mathbf{y} \quad (8)$$

$$\sigma_k^{2(q+1)} = \frac{\sum_{t=1}^n \tau_k(y_t; \boldsymbol{\theta}^{(q)}) (y_t - (\beta_{k0}^{(q+1)} + \beta_{k1}^{(q+1)} t))^2}{\sum_{t=1}^n \tau_k(y_t; \boldsymbol{\theta}^{(q)})} \quad (9)$$

$$= (\mathbf{y} - \mathbf{X}^T \boldsymbol{\beta}^{(q+1)}) \mathbf{W}^{(q)} (\mathbf{y} - \mathbf{X}^T \boldsymbol{\beta}^{(q+1)}) / \text{trace}(\mathbf{W}^{(q)}) \quad (10)$$

avec $\mathbf{W}^{(q)} = \text{diag}(\tau_{11}, \dots, \tau_{n1})$ et \mathbf{X} la matrice de dimensions $n \times (d+1)$ de lignes $(1, t)$ pour $t = 1, \dots, n$.

On montre que la mise à jour des paramètres des poids logistiques s'effectue par l'algorithme de Newton-Raphson qui consiste à partir d'un modèle initial de paramètres $\mathbf{w}^{(0)}$ et à mettre à jour, à chaque itération m , les paramètres selon l'équation de mise à jour suivante

$$\begin{aligned} \mathbf{w}^{(m+1)} &= \mathbf{w}^{(m)} + (\mathbf{X}^T \mathbf{W}^{(m)} \mathbf{X})^{-1} \mathbf{X}^T (\boldsymbol{\tau} - \mathbf{p}^{(m)}) \\ &= (\mathbf{X}^T \mathbf{W}^{(m)} \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W}^{(m)} \tilde{\mathbf{y}} \end{aligned} \quad (11)$$

où :

- \mathbf{X} est la matrice de dimensions $n \times 2$ de lignes $(1, t)$ pour $t = 1, \dots, n$;
- $\boldsymbol{\tau}$ est le vecteur colonne de dimension $n \times 1$ des probabilités à posteriori τ_{t1} : $\boldsymbol{\tau} = (\tau_{11}, \dots, \tau_{n1})^T$;
- \mathbf{p} est le vecteur colonne de dimension $n \times 1$ des probabilités : $\mathbf{p} = (\pi(\mathbf{x}_1; \boldsymbol{\theta}), \dots, \pi(\mathbf{x}_n; \boldsymbol{\theta}))^T$ avec $\pi(\mathbf{x}_i; \boldsymbol{\theta}) = \mathbb{P}(Y_i = 1 | \mathbf{x}_i; \boldsymbol{\theta}) = \frac{\exp(\beta_k^T \mathbf{x}_i)}{1 + \exp(\beta_k^T \mathbf{x}_i)}$;
- \mathbf{W} est la matrice diagonale de dimension $n \times n$ d'éléments $\pi(\mathbf{x}_1; \boldsymbol{\theta}) (1 - \pi(\mathbf{x}_n; \boldsymbol{\theta}))$: $\mathbf{W} = \text{diag}(\mathbf{p})$.
- $\tilde{\mathbf{y}} = \mathbf{X} \boldsymbol{\theta}^{(m)} + (\mathbf{W}^{(m)})^{-1} (\boldsymbol{\tau} - \mathbf{p}^{(m)})$

De part la forme de (11) qui correspond à celle de l'estimateur des moindres carrés pondérés (avec une matrice de poids \mathbf{W}) on appelle l'algorithme Newton-Raphson dans ce cas l'algorithme IRLS (Iterative Reweighted Least Squares pour moindres carrés pondérés itératifs).

Travail demandé : Implémenter l'algorithme et le tester sur la série temporelle fournie.

On pourra commencer par le cas d'un processus latent à deux états, en le testant sur une série temporelle simulée.