

**Consignes :**

- Sont interdits : Documents, calculettes, téléphones, écouteurs, ordinateurs, tablettes.
- Il est interdit de composer avec un crayon.
- Votre feuille double d'examen doit porter, à l'emplacement réservé, vos nom, prénom, et signature.
- Cette zone réservée doit être cachée par collage.
- Vos feuilles intercalaires doivent être toutes numérotées.
- Le barème est donné à titre indicatif.

On considère une série temporelle  $(Y_1, \dots, Y_n)$ , avec  $Y_t \in \mathbb{N}$ , régie par un processus latent  $(Z_1, \dots, Z_n)$  à  $K$  états où  $Z_t$  représente l'état latent à l'instant  $t$  ( $t = 1, \dots, n$ ).  $Z_t \in \{1, 2, \dots, K\}$ ,  $K \in \mathbb{N}^*$ . On dispose d'une série observée  $(y_1, \dots, y_n)$ . On suppose que pour chaque état  $k$ , la variable observée  $Y_t$  est modélisé en fonction du temps par le modèle log-linéaire suivant

$$\ln(\lambda_k(t; \boldsymbol{\beta}_k)) = \boldsymbol{\beta}_k^T \mathbf{x}_t \quad (1)$$

où  $\mathbf{x}_t = (1, t)^\top$  et  $Y_t|Z_t = k; \boldsymbol{\beta}_k \sim \mathcal{P}(\lambda_k(t; \boldsymbol{\beta}_k))$  de loi Poisson

$$\mathbb{P}(Y_t = y_t|Z_t = k; \lambda_k(t; \boldsymbol{\beta}_k)) = \frac{e^{-\lambda_k(t; \boldsymbol{\beta}_k)}(\lambda_k(t; \boldsymbol{\beta}_k))^{y_t}}{y_t!}, \quad \forall y_t \in \mathbb{N}, \quad (2)$$

qu'on notera  $\text{Poisson}(y_t; \lambda_k(t; \boldsymbol{\beta}_k))$ . La probabilité de l'état  $k$  à l'instant  $t$  définie par le modèle logistique :

$$\mathbb{P}(Z_t = k; \mathbf{w}) = \frac{e^{\mathbf{w}_k^\top \mathbf{x}_t}}{1 + \sum_{\ell=1}^K e^{\mathbf{w}_\ell^\top \mathbf{x}_t}}, \quad (3)$$

où  $\mathbf{w} = (\mathbf{w}_1^\top, \dots, \mathbf{w}_{K-1}^\top)^\top$  et  $\mathbf{w}_K = \mathbf{0}$ . On notera par  $\pi_k(t; \mathbf{w})$  cette probabilité.

1). Montrer que la loi de la variable observée est définie par

$$\mathbb{P}(Y_t = y_t; \boldsymbol{\theta}) = \sum_{k=1}^K \pi_k(t; \mathbf{w}) \text{Poisson}(y_t; \lambda_k(t; \boldsymbol{\beta}_k)) \quad (4)$$

$\boldsymbol{\theta}$  étant le vecteur paramètre inconnu du modèle.

L'objectif est de segmenter la série temporelle sur la base du modèle (4). Pour cela, on estime  $\boldsymbol{\theta}$  à partir des données en maximisant la log-vraisemblance  $L(\boldsymbol{\theta}) = \sum_{t=1}^n \ln \mathbb{P}(Y_t = y_t; \boldsymbol{\theta})$  par l'algorithme EM. On montre que celui-ci consiste à partir d'un modèle initial de paramètre  $\boldsymbol{\theta}^{(0)}$  et alterner à chaque itération  $q$  entre les deux étapes E- et M- suivantes jusqu'à la convergence :

**Étape E :** Calcul de la fonction  $Q(\boldsymbol{\theta}; \boldsymbol{\theta}^{(q)})$  définie par :

$$Q(\boldsymbol{\theta}; \boldsymbol{\theta}^{(q)}) = \sum_{t=1}^n \sum_{k=1}^K \tau_k(t; \boldsymbol{\theta}^{(q)}) \ln[\pi_k(t; \mathbf{w}) \text{Poisson}(y_t; \lambda_k(t; \boldsymbol{\beta}_k))] \quad (5)$$

où  $\tau_k(t; \boldsymbol{\theta}^{(q)}) = \mathbb{P}(Z_t = k|y_t; \boldsymbol{\theta}^{(q)})$  est la probabilité a posteriori de l'état  $k$  à l'instant  $t$ .

**Étape M :** Mise à jour des paramètres du modèle en calculant  $\boldsymbol{\theta}^{(q+1)}$  définie par :

$$\boldsymbol{\theta}^{(q+1)} = \arg \max_{\boldsymbol{\theta}} Q(\boldsymbol{\theta}; \boldsymbol{\theta}^{(q)}). \quad (6)$$

2. Donner le vecteur paramètre du modèle, noté  $\boldsymbol{\theta}$ .
3. Montrer que l'étape E- consiste à calculer les probabilités a posteriori définies par :

$$\tau_k(t; \boldsymbol{\theta}^{(q)}) = \mathbb{P}(Z_t = k | y_t; \boldsymbol{\theta}^{(q)}) = \frac{\pi_k(t; \mathbf{w}^{(q)}) \text{Poisson}(y_t; \lambda_k(t, \boldsymbol{\beta}_k^{(q)}))}{\mathbb{P}(Y_t = y_t; \boldsymbol{\theta}^{(q)})}, \quad \forall t = 1, \dots, n \quad (7)$$

4. Afin de maximiser (5) par rapport aux vecteurs  $\boldsymbol{\beta}_k$ , montrer que

$$\frac{\partial Q(\boldsymbol{\theta}; \boldsymbol{\theta}^{(q)})}{\partial \boldsymbol{\beta}_k} = \sum_{t=1}^n \tau_k(t; \boldsymbol{\theta}^{(q)}) \mathbf{x}_t \left( y_t - e^{\boldsymbol{\beta}_k^\top \mathbf{x}_t} \right). \quad (8)$$

5. Cette dérivée n'admet pas de racine analytique ; Ainsi, pour cette maximisation, on utilise l'algorithme Newton-Raphson pour la mise à jour des  $\beta_k$ . Montrer que à chaque itération  $m$  de cet algorithme, la mise à jour est donnée par l'équation suivante :

$$\boldsymbol{\beta}_k^{(m+1)} = \boldsymbol{\beta}_k^{(m)} + \left[ \sum_{t=1}^n \tau_k(t; \boldsymbol{\theta}^{(q)}) e^{\boldsymbol{\beta}_k^\top \mathbf{x}_t} \mathbf{x}_t \mathbf{x}_t^\top \right]_{\boldsymbol{\beta}_k = \boldsymbol{\beta}_k^{(m)}}^{-1} \sum_{t=1}^n \tau_k(t; \boldsymbol{\theta}^{(q)}) \mathbf{x}_t \left( y_t - e^{\boldsymbol{\beta}_k^\top \mathbf{x}_t} \right)_{\boldsymbol{\beta}_k = \boldsymbol{\beta}_k^{(m)}} \quad (9)$$

6. Donner une formulation vectorielle de cette mise à jour
7. En déduire la formulation sous forme de moindres cassés itératifs pondérés (IRLS) de cette mise à jour
8. Donner la forme générale de l'algorithme de mise à jour du vecteur  $\mathbf{w}$ .
9. Soit  $\hat{\boldsymbol{\theta}}$  le vecteur paramètre estimé par l'algorithme EM. En déduire la séquence optimale des états  $(\hat{Z}_1, \dots, \hat{Z}_n)$
10. Soit  $K = 2$ . Montrer que la mise à jour itérative du vecteur  $\mathbf{w}$  à chaque itération  $s$  de l'algorithme Newton-Raphson est donnée par :

$$\mathbf{w}^{(s+1)} = \mathbf{w}^{(s)} + \left[ \sum_{t=1}^n \mathbf{x}_t \mathbf{x}_t^\top \pi(t; \mathbf{w}) (1 - \pi(t; \mathbf{w})) \right]_{\mathbf{w}=\mathbf{w}^{(s)}}^{-1} \sum_{t=1}^n \mathbf{x}_t \left( \tau_t(\boldsymbol{\theta}^{(q)}) - \pi(t; \mathbf{w}) \right)_{\mathbf{w}=\mathbf{w}^{(s)}} \quad (10)$$

où  $\pi(t; \mathbf{w}) = \frac{e^{\mathbf{w}^\top \mathbf{x}_t}}{1 + e^{\mathbf{w}^\top \mathbf{x}_t}}$  est la probabilité de l'un des deux états.

11. Donner une formulation vectorielle de cette mise à jour
12. En déduire la formulation IRLS de cette mise à jour