



(Chaînes de
Markov cauchées)

- (X_k) C.M. de matrice de transition P et loi initiale π
- Conditionnellement à (X_1, \dots, X_n) , les (Y_i) sont indép. et la loi de Y_k dépend seulement de la valeur de X_k , i.e.

$$\begin{aligned} \mathbb{P}(Y_{1:n} = y_{1:n} \mid X_{1:n} = x_{1:n}) &= \prod_{k=1}^n \mathbb{P}(Y_k = y_k \mid X_k = x_k) \\ &= \prod_{k=1}^n Q(x_k, y_k). \end{aligned}$$

Consequences:

- $(X_m, Y_m)_{m \geq 1}$ est une CM sur $E \times F$
et

$$\begin{aligned} \mathbb{P}(X_n = x_n, Y_n = y_n \mid X_{1:n-1} = x_{1:n-1}, Y_{1:n-1} = y_{1:n-1}) \\ &= P(x_{n-1}, x_n) Q(x_n, y_n). \quad (\text{en particulier } Q \text{ ne dépend pas de } y_{n-1}) \end{aligned}$$

Preuve:

$$\begin{aligned} \mathbb{P}(X_n = x_n, Y_n = y_n \mid X_{1:n-1} = x_{1:n-1}, Y_{1:n-1} = y_{1:n-1}) &= (*) \\ &= \frac{\mathbb{P}(X_{1:n} = x_{1:n}, Y_{1:n} = y_{1:n})}{\mathbb{P}(X_{1:n-1} = x_{1:n-1}, Y_{1:n-1} = y_{1:n-1})}. \end{aligned}$$

$$\begin{aligned} \mathbb{P}(X_{1:n} = x_{1:n}, Y_{1:n} = y_{1:n}) &= \mathbb{P}(Y_{1:n} = y_{1:n} \mid X_{1:n} = x_{1:n}) \times \mathbb{P}(X_{1:n} = x_{1:n}) \\ &= \prod_{k=1}^n Q(x_k, y_k) \times \pi(x_1) \prod_{k=2}^n P(x_{k-1}, x_k) \end{aligned}$$

$$\Rightarrow (*) = Q(x_n, y_n) \times P(x_{n-1}, x_n).$$

↳ cas particulier de chaîne de Markov sur $E \times F$.

Application : finance, traitement du signal, analyse d'images, analyse de nég. géométriques

Questions :

① Estimer les paramètres :

$$\theta = (\rightarrow, P, Q)$$

↑ ↑
matrice d'observation
matrice de transition de la chaîne cachée (X_n)

loi initiale de la chaîne (X_n)_n

② Estimer la suite des états cachés (X_1, \dots, X_n) sachant les observations (y_1, \dots, y_n).

③ Problèmes liés : (prédiction)

→ Prédiction : Estimer $Z_{\theta}(X_n)$ sachant $y_{1:n-1}$

→ Filtrage : Estimer $Z_{\theta}(X_n)$ sachant $y_{1:n}$.

→ Tissage : Estimer $Z_{\theta}(X_k)$ sachant $y_{1:n}$, avec $k < n$.

① Estimation des paramètres : méthode du maximum de vraisemblance.

• La log-vraisemblance (incomplète) des observations

$$L_m(\theta) := \log \mathbb{P}_{\theta}(Y_{1:n}) = \log \left(\sum_{x_{1:n}} \mathbb{P}_{\theta}(X_{1:n} = x_{1:n}, Y_{1:n}) \right)$$

$$L_m(\theta; y_{1:n}) = \log \mathbb{P}_{\theta}(Y_{1:n} = y_{1:n})$$

| E | α termes \rightarrow impossible dès que α grand.

→ modèles avec données incomplètes

l'algorithme EM ("Expectation - Maximization")

→ pour maximiser (localement) la vraisemblance dans modèles avec données incomplètes grand le calcul de la vraisemblance complète est simple.

$y_{1:n}$: données observées, $X_{1:n}$: données manquantes

$(X_{1:n}, Y_{1:n})$: données complètes.

→ On suppose que la vraisemblance complète $\log \mathbb{P}_{\theta}(X_{1:n}, Y_{1:n})$ est facile à calculer.

Idée : (algorithme Baum-Welch dans le cadre des chaînes de Markov cachées)

- Démarer avec une valeur initiale θ_0
- À la k -ème itération :

→ L'étape E ("espérance")

$$\text{Calculer } Q(\theta | \theta_k) := \mathbb{E}_{\theta_k} [\log P_{\theta}(X_{1:n}, Y_{1:n}) | Y_{1:n}]$$

(l'espérance conditionnelle de la vraisemblance complète des données sous le paramètre constant θ_k)

↳ la meilleure info que l'on a sur la vraisemblance complète, sachant les observations

→ L'étape M ("maximization")

$$\text{Trouver } \theta_{k+1} = \underset{\theta}{\operatorname{Argmax}} Q(\theta | \theta_k).$$

- S'arrêter quand $\delta := \frac{\|\theta_{k+1} - \theta_k\|}{\|\theta_k\|} \leq \varepsilon$ (erreur relative)

ou après un nbr. max. d'itérations, ou quand

$$|\log P_{\theta_{k+1}}(Y_{1:n}) - \log P_{\theta_k}(Y_{1:n})| < \varepsilon.$$

Remarques : (*) À chaque itération, la vraisemblance des données obs. augmente

- En utilisant différents points de départ, l'algorithme peut trouver localement le max. global (l'EMV). (estimation de max. de vrais.)

Preuve de (*):

$$\text{On a } Q(\theta_{k+1} | \theta_k) \geq Q(\theta_k | \theta_k) \Leftrightarrow Q(\underline{\theta_{k+1}}, \theta_k) - Q(\underline{\theta_k}, \theta_k) \geq 0$$

$$0 \leq \mathbb{E}_{\theta_k} \left[\log \left(\frac{P_{\theta_{k+1}}(X_{1:n}, Y_{1:n})}{P_{\theta_k}(X_{1:n}, Y_{1:n})} \right) \mid Y_{1:n} \right]$$

$$\underset{\text{Jensen}}{\leq} \log \mathbb{E}_{\theta_k} \left[\frac{P_{\theta_{k+1}}(X_{1:n}, Y_{1:n})}{P_{\theta_k}(X_{1:n}, Y_{1:n})} \mid Y_{1:n} \right]$$

$$= \log \left\{ \sum_{x_{1:n}} \frac{P_{\theta_{k+1}}(X_{1:n} = x_{1:n}, Y_{1:n})}{P_{\theta_k}(X_{1:n} = x_{1:n}, Y_{1:n})} P_{\theta_k}(X_{1:n} = x_{1:n} | Y_{1:n}) \right\}$$

$$= \log \left(\sum_{x_{1:n} \in E^n} \frac{P_{\theta_{k+1}}(X_{1:n} = x_{1:n}, Y_{1:n})}{P_{\theta_k}(Y_{1:n})} \right) = \log \left(\frac{P_{\theta_{k+1}}(Y_{1:n})}{P_{\theta_k}(Y_{1:n})} \right).$$

Donc $P_{\theta_{k+1}}(Y_{1:n}) \geq P_{\theta_k}(Y_{1:n})$.

Dans notre cas :

4

- Calcul de la log-maissonblance complète :

$$\log \mathbb{P}_{\theta}(\mathbf{X}_{1:n}, \mathbf{Y}_{1:n}) = \log (\varphi(\mathbf{x}_1) \prod_{k=2}^n p(\mathbf{x}_{k-1}, \mathbf{x}_k) \cdot \prod_{k=1}^n Q(\mathbf{x}_k, \mathbf{y}_k)) \\ = \log (\varphi(\mathbf{x}_1)) + \sum_{k=2}^n \log p(\mathbf{x}_{k-1}, \mathbf{x}_k) + \sum_{k=1}^n \log Q(\mathbf{x}_k, \mathbf{y}_k).$$

L'espérance conditionnelle sous le paramètre θ^* (θ_k à l'étape k) constant

$$\underline{Q(\theta | \theta^*)} = \mathbb{E}_{\theta^*} [\log \mathbb{P}_{\theta}(\mathbf{X}_{1:n}, \mathbf{Y}_{1:n}) | \mathbf{Y}_{1:n}] \\ = \sum_{x \in E} \log (\varphi(x)) \times \mathbb{P}_{\theta^*}(\mathbf{X}_1 = x | \mathbf{Y}_{1:n}) \\ + \sum_{k=2}^n \sum_{z, z' \in E} \log (p(z, z')) \times \mathbb{P}_{\theta^*}(\mathbf{X}_{k-1} = z, \mathbf{X}_k = z' | \mathbf{Y}_{1:n}) \\ + \sum_{k=1}^n \sum_{x \in E} \log Q(x, \mathbf{y}_k) \times \mathbb{P}_{\theta^*}(\mathbf{X}_k = x | \mathbf{Y}_{1:n}).$$

↳ On a besoin de calculer $\mathbb{P}_{\theta}(\mathbf{X}_k | \mathbf{Y}_{1:n})$ et $\mathbb{P}_{\theta}(\mathbf{X}_{k-1}, \mathbf{X}_k | \mathbf{Y}_{1:n})$

Prop. **Prévision et Filtrage** : Pour $\theta = (\varphi, P, Q)$, $x \in E$, $y_{1:n} \in F^n$ on a

- $\mathbb{P}_{\theta}(\mathbf{X}_n = x | \mathbf{Y}_{1:n-1} = y_{1:n-1}) = \sum_{z \in E} \underbrace{\mathbb{P}_{\theta}(\mathbf{X}_{n-1} = z | \mathbf{Y}_{1:n-1} = y_{1:n-1}) \times P(z, x)}_{\text{"prévision"}}$
- $\mathbb{P}_{\theta}(\mathbf{X}_n = x | \mathbf{Y}_{1:n} = y_{1:n}) = \frac{\mathbb{P}_{\theta}(\mathbf{X}_n = x | \mathbf{Y}_{1:n-1} = y_{1:n-1}) \times Q(x, y_n)}{\sum_{z \in E} \mathbb{P}_{\theta}(\mathbf{X}_n = z | \mathbf{Y}_{1:n-1} = y_{1:n-1}) \times Q(z, y_n)}$

Preuve :

↳ algo. récurif (forward), avec valeurs initiales

$$\mathbb{P}_{\theta}(\mathbf{X}_1 = x | \mathbf{Y}_1 = y) = \frac{\mathbb{P}(Y_1 = y | X_1 = x) \mathbb{P}(X_1 = x)}{\mathbb{P}(Y_1 = y)} = \frac{\varphi(x) Q(x, y)}{\sum_{z \in E} \varphi(z) Q(z, y)}.$$

- $\mathbb{P}_{\theta}(\mathbf{X}_n = x | \mathbf{Y}_{1:n-1} = y_{1:n-1}) = \sum_{z \in E} \underbrace{\mathbb{P}_{\theta}(\mathbf{X}_n = x | \mathbf{X}_{n-1} = z, \mathbf{Y}_{1:n-1} = y_{1:n-1})}_{P(z, x)} \times \mathbb{P}_{\theta}(\mathbf{X}_{n-1} = z | \mathbf{Y}_{1:n-1} = y_{1:n-1}).$
- $\mathbb{P}_{\theta}(\mathbf{X}_n = x | \mathbf{Y}_{1:n} = y_{1:n}) = \mathbb{P}_{\theta}(\mathbf{X}_n = x | \mathbf{Y}_{1:n-1} = y_{1:n-1}, \mathbf{Y}_n = y_n) \quad Q(x, y_n) !$
 $= \frac{\mathbb{P}_{\theta}(\mathbf{X}_n = x, \mathbf{Y}_n = y_n | \mathbf{Y}_{1:n-1} = y_{1:n-1})}{\mathbb{P}(\mathbf{Y}_n = y_n | \mathbf{Y}_{1:n-1} = y_{1:n-1})} = \frac{\mathbb{P}(\mathbf{X}_n = x | \mathbf{Y}_{1:n-1} = y_{1:n-1}) \times \mathbb{P}(\mathbf{Y}_n = y_n | \mathbf{X}_n = x, \mathbf{Y}_{1:n-1} = y_{1:n-1})}{\sum_z \mathbb{P}(\mathbf{X}_n = z | \mathbf{Y}_{1:n-1} = y_{1:n-1}) \times Q(z, y_n)}.$

prévision(n) ← filtre(n-1) ← préd(n-1) ← filtrage(n-2) ← ... ← filtrage(1)

Remarque (Lemme) : Conditionnellement à X_n ,

Y_n est indépendante de $Y_{1:n-1}, X_{1:n-1}$.

(et $Y_{n:m+n}$)

$$\text{On va montrer. } \mathbb{P}(Y_n = y_n \mid X_n = x, Y_{1:n-1} = y_{1:n-1}) = \mathbb{P}(Y_n = y_n \mid X_n = x) = Q(x, y_n)$$

$$\mathbb{P}(Y_n = y_n, X_n = x, Y_{1:n-1} = y_{1:n-1}) = \sum_{x_{1:n-1}} \mathbb{P}(X_{1:n-1} = x_{1:n-1}, X_n = x, Y_{1:n} = y_{1:n})$$

$$= \sum_{x_{1:n-1}} \sum_{k=2}^{n-1} P(x_{k-1}, x_k) \times Q(x_k, y_k) \cdot Q(x_1, y_1) Q(x_1, y_m) P(x_n, x)$$

$$\mathbb{P}(X_n = x_n, Y_{1:n-1} = y_{1:n-1}) = \sum_{y_m} \dots$$

$$= \sum_{y_{1:n-1}} \pi(x_1) Q(x_1, y_1) P(x_{n-1}, x) \prod_{k=2}^{n-1} P(x_{k-1}, x_k) Q(x_k, y_k)$$

$$\hookrightarrow \mathbb{P}(Y_n = y_n \mid X_n = x, Y_{1:n-1} = y_{1:n-1}) = Q(x, y_n)$$

Prop.

Lissage

Pour $2 \leq k \leq n$, $y_{1:n} \in F^n$, on a

$$\bullet \mathbb{P}(X_{k-1} = x, X_k = x' \mid Y_{1:n} = y_{1:n}) = P(x, x') \frac{\mathbb{P}(X_k = x' \mid Y_{1:k-1} = y_{1:k-1})}{\mathbb{P}(X_k = x' \mid Y_{1:k-1} = y_{1:k-1})} \times \mathbb{P}(X_k = x' \mid Y_{1:n} = y_{1:n})$$

et pour $1 \leq k \leq n-1$,

$$\bullet \mathbb{P}(X_k = x' \mid Y_{1:n} = y_{1:n}) = \sum_z P(z, x) \times \frac{\mathbb{P}(X_k = x' \mid Y_{1:k} = y_{1:k})}{\mathbb{P}(X_{k+1} = z \mid Y_{1:k} = y_{1:k})} \times \mathbb{P}(X_{k+1} = z \mid Y_{1:n} = y_{1:n})$$

(formule des probas totales)
suivant $\cup \{X_{k+1} = z\}$

calcul par récurrence inverse ("backward")
("arrière") lissage(k) \leftarrow lissage($k+1$) $\leftarrow \dots \leftarrow$ lissage(n) = filtre(n)

$$\text{Preuve: } \bullet \mathbb{P}(X_{k-1} = x, X_k = x' \mid Y_{1:n} = y_{1:n}) = \underbrace{\mathbb{P}(X_k = x' \mid Y_{1:n} = y_{1:n})}_{\mathbb{P}(X_k = x' \mid X_k = x, Y_{1:n} = y_{1:n})} \times \mathbb{P}(X_{k-1} = x \mid X_k = x', Y_{1:n} = y_{1:n})$$

$$\text{et } \mathbb{P}(X_{k-1} = x \mid X_k = x', Y_{1:n} = y_{1:n}) = \frac{\mathbb{P}(X_{k-1} = x, X_k = x', Y_{1:k-1} = y_{1:k-1}, Y_{k:n} = y_{k:n})}{\mathbb{P}(X_k = x', Y_{1:k-1} = y_{1:k-1}, Y_{k:n} = y_{k:n})}$$

$$\text{En haut: } \mathbb{P}(X_k = x' \mid X_{k-1} = x, Y_{1:k-1} = y_{1:k-1}) \times \mathbb{P}(X_{k-1} = x, Y_{1:k-1} = y_{1:k-1}) \times \mathbb{P}(Y_{k:n} = y_{k:n} \mid X_k = x')$$

$$\times \mathbb{P}(Y_{k:n} = y_{k:n} \mid X_k = x', X_{k-1} = x, Y_{1:k-1} = y_{1:k-1}) \quad (\text{Lemme en haut})$$

$$= P(x, x') \times \mathbb{P}(X_{k-1} = x \mid Y_{1:k-1} = y_{1:k-1}) \times \mathbb{P}(Y_{1:k-1} = y_{1:k-1}) \times \mathbb{P}(Y_{k:n} = y_{k:n} \mid X_k = x')$$

$$\text{En bas: } \mathbb{P}(X_k = x' \mid Y_{1:k-1} = y_{1:k-1}) \times \mathbb{P}(Y_{1:k-1} = y_{1:k-1}) \times \mathbb{P}(Y_{k:n} = y_{k:n} \mid X_k = x', Y_{1:k-1} = y_{1:k-1})$$

d'où le résultat, en divisant ...

(avant - arrière")

↳ algo "forward - backward" pour calculer ces probas. condit et donc $Q(\theta/\theta^*)$.

* L'étape M ("maximization")

On cherche $\theta = (\nu, P, Q)$ qui maximise $Q(\theta/\theta')$ à $y_{1:n}$ et θ' fixes.

$$Q(\theta/\theta') = \sum_{x \in E} \log(\nu(x)) \times \mathbb{P}_{\theta'}(X_1 = x | Y_{1:n})$$

$$+ \sum_{k=2}^n \sum_{z \in E} \underbrace{\log(P(z|x))}_{\theta} \times \mathbb{P}_{\theta'}(X_{k-1} = x, X_k = z | Y_{1:n})$$

$$+ \sum_{k=1}^n \sum_{x \in E} \underbrace{\log(Q(x, y_k))}_{\theta} \times \mathbb{P}_{\theta'}(X_k = x | Y_{1:n}),$$

sous les contraintes $\sum_x \nu(x) = 1$, $\sum_z P(z|x) = 1$, $\sum_z Q(x, z) = 1$, $\forall x$

↳ maximiser séparément chacune des sommes !

• Pour Q : $\forall x \in E$ fixé, maximiser $\sum_{k=1}^n \log Q(x, y_k) \times \mathbb{P}_{\theta'}(X_k = x | Y_{1:n})$.

Ex: on g. la somme est maximale pour $\hat{Q}(x, y) = \sum_{k=1}^n \mathbb{P}_{\theta'}(X_k = x, Y_k = y) \times \mathbb{P}(X_k = x | Y_{1:n})$

De la même façon on obtient :

$$\hat{\nu}(x) = \frac{\sum_{k=1}^n \mathbb{P}_{\theta'}(X_k = x, Y_k = y) \mathbb{P}_{\theta'}(X_k = x | Y_{1:n} = y_{1:n})}{\sum_{k=1}^n \mathbb{P}_{\theta'}(X_k = x | Y_{1:n} = y_{1:n})}$$

$$\begin{aligned} \hat{P}(z, x) &= \frac{\sum_{k=2}^n \mathbb{P}_{\theta'}(X_{k-1} = x, X_k = z | Y_{1:n} = y_{1:n})}{\sum_z \sum_{k=2}^n \mathbb{P}_{\theta'}(X_{k-1} = x, X_k = z | Y_{1:n} = y_{1:n})} \\ &= \frac{\sum_{k=2}^n \mathbb{P}_{\theta'}(X_{k-1} = x, X_k = z | Y_{1:n} = y_{1:n})}{\sum_{k=1}^n \mathbb{P}_{\theta'}(X_k = z | Y_{1:n} = y_{1:n})} \end{aligned}$$

$$\hat{\nu}(x) = \mathbb{P}_{\theta'}(X_1 = x | Y_{1:n} = y_{1:n})$$

intuitivement aussi :

Lemme: Espace discret, $p \in \text{Prob}(E)$. Alors la fonction $\mathcal{H}_p: \text{Prob}(E) \rightarrow \mathbb{R}$

fonction $\mathcal{H}_p(p') = \sum_{x \in E} p(x) \log p'(x)$ est maximale pour $p' = p$.

(on suppose que $\mathcal{H}_p(p) > -\infty$. $-\mathcal{H}_p(p)$ est l'entropie de p .)

Calcul de la vraisemblance des observations pour $\hat{\theta}$ obtenu avec l'algo EM

On a vu que

$$\underset{\theta}{\mathbb{P}}(Y_n = y_n \mid Y_{1:n-1} = y_{1:n-1}) = \sum_z \underset{\theta}{\mathbb{P}}(X_n = z \mid Y_{1:n-1} = y_{1:n-1}) \times \hat{Q}(z \mid y_n)$$

||

$$\frac{\underset{\theta}{\mathbb{P}}(Y_{1:n} = y_{1:n})}{\underset{\theta}{\mathbb{P}}(Y_{1:n-1} = y_{1:n-1})}$$

→ calcul par récurrence → en faisant au log

car la vraisemblance est très petite

En pratique: exécuter l'algorithme EM avec plusieurs points de départ et choisir $\hat{\theta}$ qui donne la plus grande vraisemblance!

② Estimer la suite des états cachés

À la fin de l'algorithme EM, on a accès aux probas

$$\underset{\theta}{\mathbb{P}}(X_k = x \mid Y_{1:n}), \forall x \in \mathcal{X}_k$$

Une solution possible: $\hat{X}_k = \operatorname{Argmax}_x \underset{\theta}{\mathbb{P}}(X_k = x \mid Y_{1:n})$
(maximum a posteriori)

③ Une autre solution:

algo de Viterbi pour trouver

$$\hat{X}_{1:n} = \operatorname{Argmax}_{x_{1:n}} \underset{\theta}{\mathbb{P}}(X_{1:n} = x_{1:n} \mid Y_{1:n})$$

(programmation dynamique)

Pb.: instable / instable si on entre la dernière obs. y_n , $\hat{X}_{1:n}$ change complètement.

④ Variante de l'algorithme EM.

: SEM
stochastic

- Étape S ("simulation"): On tire au hasard une réalisation de la suite $X_{1:n}$ suivant la loi $\underset{\theta}{\mathbb{P}}_k(X_{1:n} = \cdot \mid Y_{1:n})$
- Étape M: On choisit θ_{k+1} qui maximise $\theta_{k+1} = \operatorname{Argmax}_{\theta} \underset{\theta}{\mathbb{P}}(X_{1:n} = x_{1:n}^{(k)} \mid Y_{1:n} = y_{1:n})$

Remarque: On a, pour $A_{k-1} \in \sigma(X_0, X_1, \dots, X_{k-1})$

$$\mathbb{P}(X_{k+1} = x_{k+1} \mid X_k = x_k, A_{k-1}, Y_{1:n}) \\ = \mathbb{P}(X_{k+1} = x_{k+1} \mid X_k = x_k, Y_{1:n}),$$

Preuve (idée):

Calculer $\mathbb{P}(X_{k+1} = x_{k+1} \cap X_k = x_k \cap A_{k-1} \cap Y_{1:n})$

et $\mathbb{P}(X_k = x_k \cap A_{k-1} \cap Y_{1:n})$

et m.g. le rapport ne dépend pas de A_{k-1} .

Pour estimer les états cachés $X_{k:l}$, pour $1 \leq k < l \leq n$

on maximise $\hat{\mathbb{P}}(X_{k:l} = ; x_{k:l} \mid Y_{1:n})$.

En utilisant la remarque ci-dessus, on peut montrer (etc.)

$$\text{gve } \hat{\mathbb{P}}(X_{k:l} = x_{k:l} \mid Y_{1:n}) = \frac{\hat{\mathbb{P}}(X_k = x_k, X_{k+1} = x_{k+1} \mid Y_{1:n})}{\hat{\mathbb{P}}(X_{k+1} = x_{k+1}, X_{k+2} = x_{k+2} \mid Y_{1:n})} \times \dots \times \frac{\hat{\mathbb{P}}(X_{l-1} = x_{l-1}, X_l = x_l \mid Y_{1:n})}{\hat{\mathbb{P}}(X_{l-1} = x_{l-1} \mid Y_{1:n})}$$

avec toutes ces probabilités calculées dans l'algorithme forward-backward.