

CHAINE DE MARKOV CM

CHAINE DE MARKOV

$\{X_n; n \in \mathbb{N}\}$ une suite de variables aléatoires ayant le même ensemble des états $E = \{E_1, E_2, \dots, E_m\}$
 X_n représente l'état au temps t_n .

On suppose la propriété de Markov :

$$\begin{aligned} P(X_n = E_j / X_0 = E_{i_0}, X_1 = E_{i_1}, \dots, X_{n-1} = E_{i_{n-1}}) \\ = P(X_n = E_j / X_{n-1} = E_{i_{n-1}}) = a_{ij} \end{aligned}$$

On suppose aussi la propriété d'homogénéité :

$$P(X_n = E_j / X_{n-1} = E_i) = a_{ij} \quad (\text{indépendant de } n)$$

On définit la matrice des probabilités de transitions : $A = [a_{ij}]_{i,j=1,\dots,m}$

On définit en plus la table des probabilités de l'état initial :

$$\pi = (\pi_1, \pi_2, \dots, \pi_m) \text{ où } \pi_k = \text{Prob}(X_0 = E_k)$$

Ainsi, la chaîne de Markov sera caractérisée par :


E, A et π

Graphe des probabilités de transitions


On représente la chaîne par un graphe :

- Ensemble de sommets $E = \{E_1, E_2, \dots, E_m\}$
- Ensemble des arcs défini par : $\{E_i \rightarrow E_j / a_{ij} > 0\}$


Exemple 1



Exemple 2



Exemple 3



Probabilités des états

On note par $p_n = (p_n(1), \dots, p_n(j), \dots, p_n(k))$ la table définissant les probabilités des états au temps t_n : $p_n(j) = \text{Prob}\{X_n = E_j\}$

On a alors : $\mathbf{p}_{n+1} = \mathbf{p}_n \mathbf{A}$

La probabilité d'avoir observer une séquence d'états :

$$E_{i_0}, E_{i_1}, \dots, E_{i_k}, \dots, E_{i_n}$$

Est égale à :

$$p_0(E_{i_0}) a_{i_0 i_1} a_{i_1 i_2} \dots a_{i_k i_{k+1}} \dots a_{i_{n-1} i_n}$$

Probabilité de l'état initial π_{i_0}

Probabilités de transitions

Génération d'une séquence d'états par une chaîne de Markov

La chaîne de Markov peut être considérée comme un générateur de séquences de longueur variable L : $S = E_{i_0} E_{i_1} \dots E_{i_k} \dots E_{i_L}$

Initialisation :

E_{i_0} est la réalisation de la variable X_0 dont la table de probabilité est $p(X_0 = E_{i_0})$.

Génération de l'élément E_{i_k}

E_{i_k} est la réalisation de la variable conditionnelle $P(X_k = ? / X_{k-1} = E_{i_{k-1}})$ dont la répartition de probabilité est la table :

$$(a_{i_{k-1}1}, a_{i_{k-1}2}, \dots, a_{i_{k-1}n})$$

On a alors :
$$p(S) = \underbrace{P(X_0 = E_{i_0})}_{\pi_{i_0}} \times a_{i_0 i_1} \times a_{i_1 i_2} \times \dots \times a_{i_{L-1} i_L}$$

CHAINE DE MARKOV CACHEE CMC

Exemple

Exemple : On dispose de 3 urnes contenant des boules blanches, noires et grises dans des proportions différentes.

On note par $P(B/u_i)$, $P(N/u_i)$, $P(G/u_i)$ les probabilités de tirer une boule blanche, noir ou grise de l'urne u_i ($i=1,2,3$).

Un opérateur **invisible** choisi, à des instants réguliers, une urne et tire une boule de cette urne et annonce la couleur. S'il choisi T urnes il annoncera (à un observateur) la séquence des T couleurs tirés notée O_T .

Ainsi, au temps t , l'opérateur choisi une urne u_t et tire une boule de couleur o_t de cette urne. On suppose que le tirage d'une boule au temps t est indépendant du tirage de la boule au temps $t-1$.

Exemple (suite)

On fait l'hypothèse que l'opérateur choisi la séquence des urnes suivant un modèle d'une **chaîne de Markov** ayant pour paramètres $\{\pi, \mathbf{A}\}$ et dont les états sont les urnes. Cette chaîne sera dite **cachée** (puisque l'opérateur est invisible) .

Ainsi :

La séquence $\mathbf{U}_T = u_1 u_2 \dots u_T$ sera dite la **séquence des états cachée** (car invisible) et elle est générée par la chaîne de Markov cachée.

la séquence $\mathbf{O}_T = o_1 o_2 \dots o_T$ sera dite la **séquence des observations** qui sera annoncée à l'observateur.

CMC : définition

chaîne
de
Markov

- M : le nombre des symboles observables.
- N : le nombre des états cachés.
- $V = \{v_1, v_2, \dots, v_M\}$: l'ensemble des symboles observables.
- $Q = \{q_1, q_2, \dots, q_N\}$: l'ensemble des états cachés.
- $\Pi = [\pi_i]$: la table de probabilités de l'état initial de la CM.
- $A = [a_{ij}]$: matrice $N \times N$ des probabilités de transition de la CM.
- $B = [b_i(v_k)]$: matrice $N \times M$ avec $b_i(v_k) = P(v_k/q_i)$ (probabilité de l'émission de l'état v_k par l'état q_i).
- T : taille d'une séquence d'observations.

Notation : les paramètres du modèle seront notés par :

$$\lambda = (\pi, \mathbf{A}, \mathbf{B})$$

Génération d'une séquence d'observations

Une séquence d'observations $O_T = o_1 o_2 \dots o_T$ est générée de la manière suivante :

1. Faire $t=1$, Choisir un état initial selon la distribution Π .
2. i_t étant l'indice de l'état au temps t , choisir o_t selon la table de probabilité de l'émission de l'état i_t (la table $b_i()$).
3. Choisir l'état $q_{i_{t+1}}$ selon les probabilités de transitions $[a_{i_{t+1}}]$
Faire $t=t+1$.
4. Si $t < T$ alors **retourner à l'étape 3** sinon **Fin**.

$I_T = i_1 i_2 \dots i_T$: la séquence des indices des états cachés.

Trois problèmes

Problème 1 :

Etant donné la séquence d'observations $O_T = o_1 o_2 \dots o_T$ et le modèle de paramètre $\lambda = (\pi, A, B)$, comment calculer $P(O_T / \lambda)$?

Problème 2 :

Etant donné la séquence d'observations $O_T = o_1 o_2 \dots o_T$ comment choisir la séquence des états sous-jacentes $i_1 i_2 \dots i_T$ et qui est optimal suivant un certain critère ?

Problème 3 :

Comment ajuster les paramètres $\lambda = (\pi, A, B)$ afin de maximiser $P(O_T / \lambda)$?

Problème 1

Calcul de $P(O_T/\lambda)$

Une manière immédiate pour calculer cette probabilité est d'énumérer toutes les séquences $I_T=i_1i_2\dots i_T$ d'états possibles et de calculer :

$$p(O_T/\lambda) = \sum_{\text{Séquences } I_T} p(O_T/\lambda, I_T) p(I_T/\lambda)$$

Avec : $P(I_T/\lambda) = \pi_{i_1} a_{i_1i_2} a_{i_2i_3} \dots a_{i_{T-1}i_T}$

$$p(O_T / I_T, \lambda) = b_{i_1}(o_1) b_{i_2}(o_2) \dots b_{i_T}(o_T)$$

Chaîne de Markov


Indépendance des observations

D'où $P(O_T, I_T/\lambda) = \prod_i b_{i_1}(o_1) a_{i_1i_2} b_{i_2}(o_2) a_{i_2i_3} b_{i_3}(o_3) \dots a_{i_{T-1}i_T} b_{i_T}(o_T)$

Mais cette formule est très coûteuse en temps de calcul.
Ordre de calcul $2TN^T$

Méthodes Forward et Backward

Ces deux méthodes utilisent implicitement le graphe suivant :



L'arc $q_i \rightarrow q_j$ existe si et seulement si $a_{ij} > 0$, il sera valué par a_{ij}


Calcul de $P(\mathbf{O}_T/\lambda)$ Méthode Forward

On définit $\alpha_t(i) = P(\underbrace{o_1 o_2 \dots o_t}_{\text{Observations partielles}} \mid i_t = i, \lambda)$

Calcul de α_t

1. $\alpha_1(i) = \pi_i b_i(o_1)$ pour $i=1, \dots, N$
2. Pour $t=1, 2, \dots, T-1$ et pour $j=1, \dots, N$

$$\alpha_{t+1}(j) = \left[\sum_{i=1}^N \alpha_t(i) a_{ij} \right] b_j(o_{t+1})$$




Calcul de $P(\mathbf{O}_T/\lambda)$ Méthode Backward

On calcule $\beta_t(i) = P(\underbrace{o_{t+1} o_{t+2} \dots o_T}_{\text{Observations partielles}} \mid i_t = i, \lambda)$

Calcul de β_t

1. $\beta_T(i) = 1$ pour $i=1, \dots, N$
2. Pour $t=T-1, \dots, 1$ et pour $i=1, 2, \dots, N$

$$\beta_t(i) = \sum_{j=1}^N \beta_{t+1}(j) a_{ij} b_j(o_{t+1})$$



Calcul de $p(\mathbf{O}_T/\lambda)$

On a :

$$p(\mathbf{O}_T / \lambda) = \sum_{i=1}^N \alpha_T(\mathbf{i})$$

$$p(\mathbf{O}_T / \lambda) = \sum_{i=1}^N \pi_i b_i(o_1) \beta_1(\mathbf{i})$$

Pour tout t

$$1 \leq t \leq T \quad P(\mathbf{O}_T | \lambda) = \sum_{i=1}^N \alpha_t(\mathbf{i}) \beta_t(\mathbf{i})$$

Problème 2 : Décodage

Détermination de la séquence cachée « optimale »

Trouver la séquence des états cachés qui explique « au mieux » la séquence des observations.

Déterminer : $\arg \max_{I_T} p(I_T | O_T)$

$$\text{Or } p(I_T / O_T, \lambda) = \frac{p(I_T, O_T / \lambda)}{p(O_T / \lambda)}$$

Déterminer $\Rightarrow \arg \max_{I_T} p(I_T, O_T / \lambda)$

Algorithme de Viterbi

Problème 2 : Algorithme de Viterbi

On définit :
$$\delta_j(t) = \max_{i_1 \dots i_{t-1}} p(i_1 \dots i_{t-1}, o_1 \dots o_{t-1}, i_t = j, o_t / \lambda)$$

La séquence des états cachés i_1, i_2, \dots, i_{t-1} qui maximise la probabilité d'avoir observé :

- les observations jusqu'au temps t-1
- l'état au temps t
- l'observation au temps t

Par définition :
$$\delta_1(i) = \pi_i b_i(o_1)$$

Problème 2 : Algorithme de Viterbi

Etape 1 : pour $i=1, \dots, N$ $\delta_1(i) = \pi_i b_i(o_1)$ et $\Psi_1(i) = 0$

Etape 2 : pour $t=2 \dots T$ faire

$$\begin{cases} \delta_t(j) = \text{Max}_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij}] b_j(o_t) \\ \Psi_t(j) = \text{Arg max}_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij}] \end{cases}$$

Etape 3 : FIN on tire
$$\begin{cases} \mathbf{p}^* = \text{Max}_{1 \leq i \leq N} [\delta_T(i)] \\ \mathbf{i}_T^* = \text{Arg max}_{1 \leq i \leq N} [\delta_T(i)] \end{cases}$$

Etape 4 : (reconstitution de la séquence)

$$\text{Pour } t=T-1, \dots, 1 \quad \mathbf{i}_t^* = \Psi_{t+1}(\mathbf{i}_{t+1}^*)$$

Problème 3

Détermination des paramètres

Etant donné un modèle et une séquence d'observation, modifier les paramètres du modèle afin de reproduire au mieux les observations.

On définit :

$$p_t(i, j) = \frac{\alpha_i(t) a_{ij} b_j(o_{t+1}) \beta_j(t+1)}{\sum_{m=1 \dots N} \alpha_m(t) \beta_m(t)}$$

La probabilité de passer de l'état q_i à l'état q_j au temps t

$$\gamma_i(t) = \sum_{j=1 \dots N} p_t(i, j)$$

Probabilité d'être à l'état q_i au temps t

Problème 3

Détermination des paramètres

$$\sum_{t=1}^{T-1} \gamma_t(i)$$

Représente la fréquence relative des transitions à travers l'état q_i

$$\sum_{t=1}^{T-1} p_t(i, j)$$

Représente la fréquence relative des transitions de l'état q_i à l'état q_j

Problème 3 (suit)

Détermination des paramètres

Algorithme

- Initialiser les paramètres $\lambda^0=(\Pi^0,A^0,B^0)$

- Répéter l'étape itérative suivante

Les paramètres courants $\lambda=(\Pi,A,B)$ permettent de calculer les nouveaux paramètres $\hat{\lambda}=(\hat{\Pi},\hat{A},\hat{B})$ par :

$$1. \quad \hat{\pi}_i = \gamma_i(\mathbf{1})$$

$$2. \quad \hat{a}_{ij} = \frac{\sum_{t=1}^T p_t(i,j)}{\sum_{t=1}^T \gamma_i(t)}$$

$$3. \quad \hat{b}_j(v_k) = \frac{\sum_{\{t:o_t=v_k\}} \gamma_t(j)}{\sum_{t=1}^T \gamma_t(j)}$$