

Nom :

Id :

Année 2022-2022

Unsupervised Learning - M2 Data Science

Examen du cours « Unsupervised Learning »

Exercice 1 : ADN

Soit une séquence d'ADN dont le premier nucléotide est a : pour tout $n \geq 1$, on note X_n la n -ième base composant la séquence d'ADN en partant d'une de ses extrémités. On suppose que (X_n) est une chaîne de Markov homogène d'espace d'états $\mathcal{A} = \{a, c, g, t\}$ et d'état initial a (on identifiera a à l'état 1, c à l'état 2, g à l'état 3 et t à l'état 4). On note Q sa matrice de transition.

1. Exprimer à l'aide de la matrice Q , la probabilité que la séquence commence par le motif $aacg$.
2. Montrer que la 4-ième base est indépendante de la seconde sachant la 3-ième base.
3. Expliquer comment simuler les n premières bases d'une séquence pour ce modèle.

Exercice 2 : Loi stationnaire d'une chaîne à deux états

Soit $(X_n)_n$ une chaîne de Markov homogène d'espace d'états $\{1, 2\}$ et de matrice de transition $Q = \begin{pmatrix} 1-p & p \\ q & 1-q \end{pmatrix}$ avec $p, q \in [0, 1]$. Si $p + q > 0$, quelle est la loi de probabilité stationnaire de la chaîne ?

Exercice 3 : Chaîne de Markov cachée

Soit $\mathcal{MC}(\boldsymbol{\pi}, A)$ une chaîne de Markov cachée à deux états cachés $\{1, 2\}$ de matrice de transition $A = \begin{pmatrix} 0.5 & 0.5 \\ 0.7 & 0.3 \end{pmatrix}$ de probabilité d'état initial $\boldsymbol{\pi} = \begin{pmatrix} 0.5 \\ 0.5 \end{pmatrix}$ et de probabilité d'émission $B = \begin{pmatrix} 0.2 & 0.9 \\ 0.8 & 0.1 \end{pmatrix}$ sur les symboles $\{\circ, \times\}$ avec $B_{1k} = P(\circ | Z = k)$ et $B_{2k} = P(\times | Z = k)$.

Attention : la convention pour B utilisée ici numérote les symboles en lignes et pas en colonnes comme vu en TD.

1. Écrire le pseudo-code de simulation d'une chaîne de Markov cachée de longueur n .

2. Écrire la log-vraisemblance complète (c'est-à-dire la loi jointe des observations et des états cachés) des paramètres d'une chaîne de Markov cachée.
3. Écrire l'espérance de cette log-vraisemblance par rapport à la loi des états cachés sachant les observations.
4. Quel algorithme est classiquement utilisé pour estimer les paramètres d'une chaîne de Markov cachée? Décrire succinctement les étapes principales de cet algorithme.

Exercice 4 : Modèle à blocs stochastiques

Soit un modèle modèle à blocs stochastiques à deux classes :

$$X_{ij} | Z_i = k, Z_j = \ell \sim \mathcal{B}(\gamma_{k\ell})$$

avec $\pi_1 = P(Z_i = 1) = \frac{1}{2} = P(Z_i = 2) = \pi_2$ et $\gamma = \begin{pmatrix} 1 & 0.05 \\ 0.05 & 0.1 \end{pmatrix}$.

1. Écrire la formule théorique de la vraisemblance complète de ce type de modèle.
2. Pourquoi un algorithme EM classique n'est pas applicable pour estimer les paramètres de ce modèle?
3. Quelle solution peut être adoptée pour estimer les paramètres?